

**Sveučilište u Zagrebu**

**Ekonomski fakultet**

**Smjer Marketing**

**Uloga umjetne inteligencije u procesu donošenja odluke o  
kupovini**

**Diplomski rad**

**Student: Alen Kesić, 0066227369**

**Mentor: Izv. prof. dr. sc. Goran Vlašić**

**Zagreb, rujan, 2019.**

**Sveučilište u Zagrebu**

**Ekonomski fakultet**

**Smjer Marketing**

**Uloga umjetne inteligencije u procesu donošenja odluke o  
kupovini**

**The role of artificial intelligence in the buying decision process**

**Diplomski rad**

**Student: Alen Kesić, 0066227369**

**Mentor: Izv. prof. dr. sc. Goran Vlašić**

**Zagreb, rujan, 2019.**

Alen Kesić

## IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je diplomski rad isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Student:

U Zagrebu, \_\_\_\_\_

\_\_\_\_\_

(potpis)

## Sadržaj

1.	Uvod .....	1
1.1.	Područje i cilj rada .....	1
1.2.	Izvori i metode prikupljanja podataka .....	2
1.3.	Sadržaj i struktura rada .....	2
2.	Strategije upravljanja tržištem kroz upravljanje procesom donošenja odluke o kupovini .....	3
2.1.	Faze procesa donošenja odluke o kupovini .....	3
2.1.1.	Spoznaja potrebe .....	5
2.1.2.	Traženje informacija .....	6
2.1.3.	Vrednovanje alternativa .....	8
2.1.4.	Kupovina .....	9
2.1.5.	Poslijekupovno ponašanje .....	9
2.2.	Čimbenici koji utječu na proces donošenja odluke o kupovini .....	10
2.2.1.	Društveni čimbenici .....	11
2.2.2.	Osobni čimbenici .....	12
2.2.3.	Psihološki procesi .....	14
2.3.	Strategije upravljanja procesom donošenja odluke o kupovini .....	15
2.3.1.	Proces prihvaćanja novog proizvoda .....	15
2.3.2.	Strategije upravljanja procesom donošenja odluke o kupovini .....	16
2.3.3.	Provođenje strategije upravljanja procesom donošenja odluke o kupovini .....	17
3.	Uloga umjetne inteligencije u procesu kupovine .....	20
3.1.	Pojmovno određenje sustava preporuke .....	20
3.1.1.	Što su sustavi preporuke? .....	20
3.1.2.	Povijesni razvoj sustava preporuke .....	22
3.2.	Pojmovno određenje koncepta umjetne inteligencije .....	23
3.2.1.	Što je umjetna inteligencija? .....	23
3.2.2.	Povijesni razvoj umjetne inteligencije .....	25

3.3. Pregled istraživanja uloge umjetne inteligencije u sustavima preporuke .....	26
3.4. Utjecaj umjetne inteligencije na proces donošenja odluke o kupovini .....	28
4. Kvalitativno istraživanje o ulozi umjetne inteligencije u procesu donošenja odluke o kupovini.....	31
4.1. Predmet i cilj istraživanja .....	31
4.2. Metodologija istraživanja .....	31
4.3. Rezultati istraživanja .....	32
4.3.1. O kompaniji.....	32
4.3.2. Uloga Amazona i Alexa-e u procesu donošenja odluke o kupovini .....	33
4.3.3. Intervju s korisnicima Amazon.com-a .....	44
4.4. Rasprava .....	46
4.5. Ograničenja istraživanja .....	47
5. Zaključak.....	49
Popis izvora .....	51
Popis slika .....	55
Popis tablica .....	55
Prilozi .....	56

## Sažetak

Ovaj rad se bavi razumijevanjem procesa donošenja odluke o kupovini od strane potrošača te na ulogu umjetne inteligencije u pojedinim fazama tog procesa obzirom na učestalost korištenja umjetno inteligentnih sustava te s obzirom na donošenje odluke o proizvodu koji zahtijevaju različite razine uključenosti.

Za potrebe rada su definirani modeli ponašanja potrošača, odnosno proces donošenje odluke, čimbenici koji utječu na odluke potrošača te strategije upravljanja procesom donošenja odluke. Osim toga je definiran i koncept umjetne inteligencije, odnosno umjetno inteligentnih sustava, njihov razvoj, utjecaj na sustave preporuke te utjecaj na proces donošenja odluke o kupovini.

Provedeno je kvalitativno istraživanje kako bi se definirala uloga umjetne inteligencije na proces donošenja odluke o kupovini na primjeru Amazonova umjetno inteligentnog sustava Alexa, obzirom na učestalost korištenja Alexa-e te s obzirom na donošenje odluke o proizvodima koji zahtijevaju različite razine uključenosti korisnika.

Rezultati istraživanja ukazuju kako trenutno umjetne inteligencije u procesu donošenja odluke zauzima sporednu ulogu za potrošača te je njena uloga trenutno izraženija na strani proizvođača, odnosno prodavača u oblikovanju marketinške strategije. Dodatno istraživanja upućuju kako će uloga umjetno inteligentnih sustava postati značajni i za potrošača te zauzimati sve značajniju ulogu u procesu donošenja odluke o kupovini.

**KLJUČNE RIJEČI:** ponašanje potrošača, proces donošenja odluke o kupovini, strategija upravljanja procesom donošenja odluke o kupovini, umjetna inteligencija, umjetno inteligentni sustavi.

## **Abstract**

This paper deals with the understanding of the consumer buying decision process and the role of artificial intelligence in certain phases of this process, given the frequency of use of artificially intelligent systems and the product decision making that require different levels of involvement.

For the purposes of the paper, consumer behavior models, decision-making processes, factors influencing consumer decisions, and decision-driven strategies are defined. In addition, the concept of artificial intelligence, artificial intelligence systems, their development, impact on recommender systems and influence on the buying decision process.

Qualitative research has been conducted to define the role of artificial intelligence in the buying decision process, using the example of Amazon's artificially intelligent Alexa system, given the frequency of use of Alexa and the decision-making of products that require different levels of customer involvement.

The results of the research indicate that artificial intelligence currently plays a supporting role in the decision-making process for costumers, and its role is currently more pronounced on the side of the manufacturer, the seller, in shaping the marketing strategy. Additionally, research suggests that the role of artificially intelligent systems will become significant for the consumer as well, and will play an increasingly important role in the buying decision process.

**KEY WORDS:** consumer behavior, buying decision process, strategy for managing the buying decision process, artificial intelligence, artificially intelligent systems.

# 1. Uvod

## 1.1. Područje i cilj rada

Korištenje suvremene tehnologije, računala, pametnih telefona i slično, postalo je uobičajeno i dostižno gotovo svakom pojedincu. Povezanost sa svijetom, putem interneta i različitih medija, danas predstavlja gotovo osnovno obilježje života. Stoga u takvim okolnostima, gdje komunikacijske barijere i barijere udaljenosti gotovo ne postoje, odnosno neutralizirane su, a tržište postaje globalizirano, ključno postaje razumjeti ponašanja potrošača. Proces donošenja odluke predstavlja niz faza koje su pod utjecajem brojnih čimbenika, kako osobnih tako i vanjskih. Stoga je ključno razumjeti kako koji čimbenici utječu na koju fazu. Uzme li se pri tome u obzir i tehnologija te njena prisutnost u svakodnevnom životu pojedinca, ona postaje značajan čimbenik procesa donošenja odluke. Suvremena tehnologija, kao što je umjetna inteligencija i njeno korištenje u procesu donošenja odluke o kupovini nudi brojne mogućnosti, s jedne strane potrošačima, a s druge marketinškim stručnjacima. Umjetno inteligentni sustavi, koji će moći predviđati i utjecati na odluke potrošača, pa čak i donositi odluke umjesto njih, predstavljaju budućnost.

Rad proučava proces donošenja odluke o kupovini te ulogu koju ima umjetna inteligencija u samom procesu. Prema dostupnoj literaturi, proces donošenja odluke o kupovini podijeljen je na sljedeće faze: spoznaja potrebe, traženje informacija, vrednovanje alternativni, kupovina i poslijekupovni procesi. Ovaj rad će naglasak staviti na ulogu umjetne inteligencije u svakoj pojedinoj fazi procesa donošenja odluke te kako umjetno inteligentnim sustavima upravljati procesom donošenja odluka o kupovini te na taj način utjecati na potrošača.

Istraživački problem, koji je u fokusu ovoga rada, je razumijevanje uloge umjetne inteligencije u procesu donošenja odluke o kupovini. Stoga je cilj ovoga rada identificirati kako i zašto umjetna inteligencija može utjecati, odnosno sudjelovati u procesu donošenja odluke o kupovini te na koji način se primjenjuju umjetno inteligentni sustavi prilikom provođenja strategija upravljanja procesom donošenja odluke o kupovini.



## **1.2. Izvori i metode prikupljanja podataka**

Za izradu rada i istraživanja i obrade ove tematike upotrijebljeni su primarni i sekundarni izvori podataka. Teorijski dio rada razrađen je pomoću sekundarnih izvora. Dakle uz pomoć knjiga koje se odnose na tu tematiku te stručni i znanstveni članci iz područja ponašanja potrošača i umjetne inteligencije, koji su dostupni putem stručnog kataloga knjižnice Ekonomskog fakulteta u Zagrebu te internetskih baza podataka kao što su Emerald, Ebsco, ResearchGate, Google Scholar, ProQuest i Elsevier. Rad također uključuje i sekundarne podatke dobivene pretraživanjem relevantnih informacija na internetu. Primarni podatci će se prikupiti intervjuiranjem korisnika umjetno inteligentnih sustava, metodom studije slučaja.

## **1.3. Sadržaj i struktura rada**

Rad sadrži nekoliko dijelova. Prvi dio rada bavi se s procesom donošenja odluke o kupovini, definiran je sam proces te su pojašnjene sve faze procesa i njihova obilježja. Osim toga u prvom dijelu rada je riječ i o čimbenicima koji utječu na proces donošenja odluke o kupovini te o strategijama upravljanja procesom donošenja odluke o kupovini.

Zatim je u drugom dijelu riječ o umjetnoj inteligenciji, što je ona, odnosno kako je definirana te na koji način umjetna inteligencija utječe na proces donošenja odluke o kupovini. Također će biti riječ i o sustavima preporuke i njenom utjecaju. Uz to će biti prikazan i pregled istraživanja uloge umjetne inteligencije u sustavima preporuke.

U trećem dijelu rada biti će riječ o empirijskom istraživanju uloge umjetne inteligencije na proces donošenja odluke o kupovini, gdje su navedeni predmet i cilj istraživanja, metodologija istraživanja, rezultati, rasprava i ograničenja istraživanja.

## **2. Strategije upravljanja tržištem kroz upravljanje procesom donošenja odluke o kupovini**

Znanstvena disciplina koja proučava proces donošenja odluke o kupovini je ponašanje potrošača. Ova znanstvena disciplina je relativno mlada, prva knjiga iz ovog područja pojavila se 1960. godine. Prema Engelu, Blackwellu i Miniardu (1995.) proučavanje ponašanje potrošača ima tri temeljna cilja:

1. Razumijevanje i predviđanje ponašanja potrošača,
2. Donošenje regulativne politike u cilju zaštite potrošača u društvu,
3. Otkrivanje uzrok-efekt relacije koja uvjetuje informiranje potrošača i obrazovanje mladih.

To znači da dobro koncipirana marketinška strategija može utjecati na potrošača i njegovo ponašanje, pod uvjetom da ima jasnu sliku svoga potrošača i da je društveno prihvatljiva (Kesić, 2006.). Renko (2009.) Kotlerovu definiciju strategije prevodi na sljedeći način: tržišno orijentirano strateško planiranje koje je upravljački proces razvijanja i održavanje veza između organizacijskih ciljeva, izvora i vještina te promjenjivih tržišnih mogućnosti. Ciljevi su strateškog planiranja dizajnirane i redizajniranje poslovanja poduzeća ili njegovih proizvoda i usluga na način da oni ostvaruju planirani profit i rast.

Obzirom da ponašanje potrošača predstavlja proces pribavljanja i konzumiranja proizvoda, usluga i ideja te se mogu identificirati motivi ponašanja potrošača u pojedinim fazama, marketinški stručnjaci moraju prepoznati i razumjeti čimbenike koji utječu na odluke kupaca, a u skladu s tim te na društveno prihvatljiv način utjecati na njihovo ponašanje (Kesić, 2006.).

### **2.1. Faze procesa donošenja odluke o kupovini**

Proces odlučivanja potrošača varira znatno o kompleksnosti. Većina je svakodnevnih odluka potrošača vrlo jednostavna. Međutim, pojedine odluke, kao što je kupovina polutrajnih dobara, zahtjeva više vremena i psihološkog napora jednog ili više članova obitelji. (Kesić, 2006.)

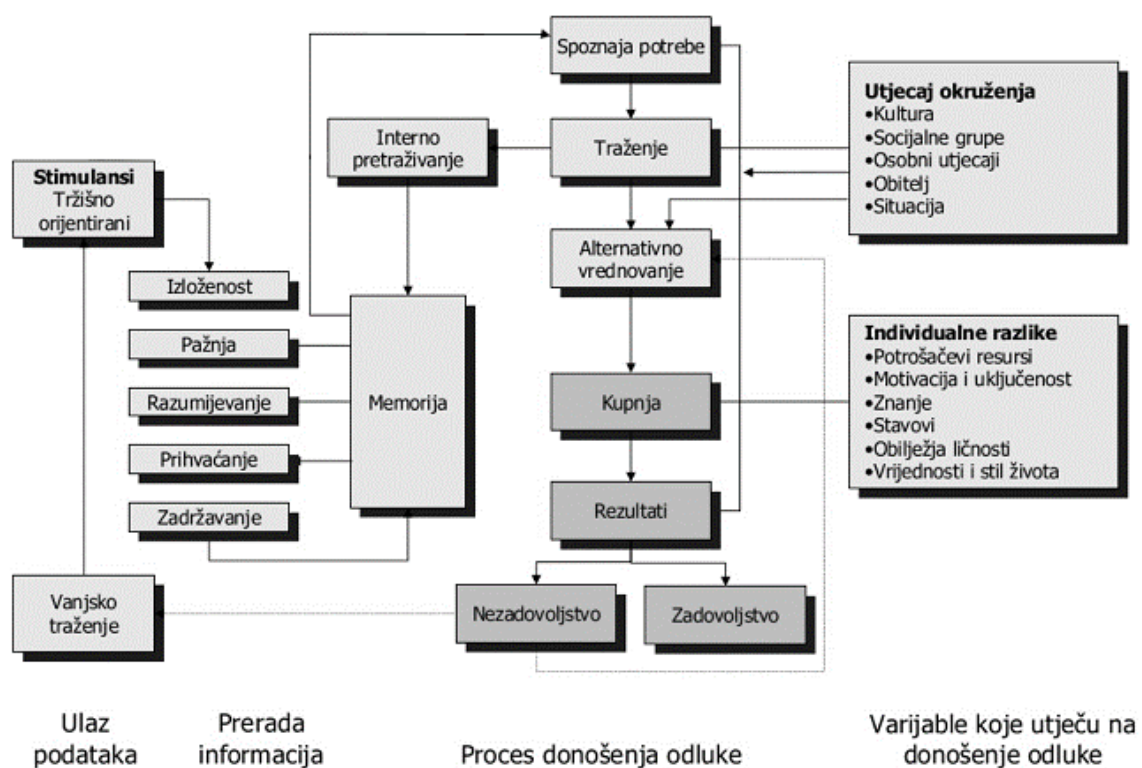
Kesić (2006.), prema kompleksnosti odluke o kupovini, kupovine dijeli na:

- Rutinske kupovine – nema napora pri donošenju odluke, ni psihološke uključenosti (npr.: kupovina kruha)
- Limitirano rješenje problema – kada se kupuje nova marka u poznatoj kategoriji, zahtjeva traženje informacija, odnosno psihološku uključenost.

- Ekstenzivno rješenje problema – kada se kupuje nepoznati proizvod u nepoznatoj kategoriji. Psihološka uključenost je maksimalan, obzirom da je potrebna znatna količina informacija i dulje vremena.

Stoga, ovisno o razini kompleksnosti odluke koju treba donijeti kupac, to će više čimbenika utjecati na donesenu odluku. Stoga, što je potrebno donijeti kompleksniju odluku, odnosno ekstenzivno rješenje problema, to će više čimbenika utjecati na tu odluku. Iz tog razloga marketinški stručnjaci moraju prepoznati koji čimbenici utječu na kupovinu u kojoj fazi te prema tome definirati marketinšku strategiju.

### 1. Složeni model ponašanja potrošača



Izvor: Engel, F. J., Blackwell, D.R., Miniard, W.p., Consumer Behavior (seventh ed.), The Dryden Press, 1995, p.53. (preuzeto iz: Ponašanje potrošača, Kesić T., 2006.)

Na prethodnom prikazu se mogu vidjeti faze u procesu donošenja odluke o kupovini te koje sve varijable mogu utjecati na donošenje odluka. Uglavnom, čimbenike koji utječu na odluku, možemo podijeliti na unutarnje i vanjske. Unutarnji se odnose na samog potrošača, njegove resurse, motivaciju i uključenost, znanje, stavove, obilježja ličnosti i vrijednosti i stil života. Dok su vanjski čimbenici, utjecaji okruženja: kultura, socijalne grupe, osobni utjecaji, obitelj i situacija. Dodatno o čemu ovisi proces donošenja odluka je ulazak podataka te prerada informacija. S jedne strane može biti unutarnje pretraživanje informacija, koje ovisi o memoriji

pojedince, a s druge vanjsko traženje, koje ovisi o tržištu (Kesić, 2006.). Obzirom na složenost procesa donošenja odluke o kupovini i važnosti za ovaj rad će se u poglavljima koja slijede razmatrati proces donošenja odluke o kupovini, a proces donošenja odluke na tržištu osobne potrošnje čine sljedeće faze:

1. Spoznaja potrebe,
2. Traženje informacija,
3. Vrednovanje alternativa,
4. Kupovina i
5. Poslije kupovni procesi.

Prema kritičkom osvrtu o modelima odlučivanja od Erasmusa, Boshooft i Rousseau (2001.), izvorno su navedene faze predložili Cox, Summers i Granobis 1983. godine. Iako postoje brojni drugi modeli procesa donošenja odluke o kupovini, njihov model je od svih dotadašnjih bio najprecizniji, prvenstveno iz razloga što u fokus stavlja i motivacijske čimbenike koji pomažu u razumijevanju kupovnih odluka.

### **2.1.1. Spoznaja potrebe**

Proces kupnje počinje kada kupac spozna problem ili potrebu. Tu potrebu može izazvati unutarnji ili vanjski poticaj. Unutarnji poticaj je čovjekova normalna potreba – za hranom, pićem ili seksom – pojavljuje se u početnoj fazi i postaje nagon: potrebu može izazvati i vanjski nagon. (Kotler, Keller, 2008.)

Kada se promatra koji oblici problema postoje, prema Kesić (2006.) su to aktivni i neaktivni. Aktivni problemi su oni kojih je potrošač svjestan ili će biti svjestan u normalnom slijedu događaja. Dok su neaktivni problemi oni kojih potrošač nije svjestan, ali to može postati procesom komunikacije ili nekim drugim tržišnim mehanizmom. Kod ove podjele se radi o podjeli sa stajališta prepoznavanja problema. S druge strane, gleda li se na problem sa stajališta očekivanja problema i urgentnosti rješavanja, oni se dijele na: rutinske, urgentne, planirane i neplanirane. Ono što razlikuje ove probleme, jest očekivanje da li će se dogoditi i da li zahtjeva trenutno rješenje ili ne.

Postoji velik broj čimbenika koji uvjetuju spoznaju problema. Ovo su neki od njih (Kesić, 2006.): neadekvatne ili potrošene zalihe, nezadovoljstvo postojećim zalihama, promjene okruženja i životnih uvjeta, individualne razlike, promjene financijskih uvjeta i marketinške

aktivnosti. Navedenih primjera čimbenika koji utječu na spoznaju problema se uglavnom odnose na donošenje odluka u uvjetima visoke uključenosti potrošača, dok kada se radi u uvjetima niske uključenosti potrošača, spoznaja problema se može izazvati raznim oblicima unapređenjem prodaje.

Obzirom da proces donošenja odluke o kupovini započinje spoznajom problema, odnosno potrebe, bez prepoznavanje iste neće doći ni do kupovine. Stoga je ključno za marketinške stručnjake prepoznavanje problema potrošača za definiranje marketinške strategije.

### **2.1.2. Traženje informacija**

Zainteresirani potrošač tražit će dodatne informacije. Razlikuju se dvije razine zainteresiranosti. Blaži oblik potrage zove se povećana pozornost. Na toj razini pojedinac jednostavno prihvaća informacije o proizvodu. Na sljedećoj razini pokreće aktivnu potragu za informacijama kako bi saznao više o proizvodu. (Kotler, Keller, 2008.)

Traženje informacija se može promatrati kao pretkupovno i stalno (s aspekta povezanosti s kupovinom) i interno i eksterno (s aspekte izvora informacija). (Kesić, 2006.)

- Pretkupovno traženje je tipičan proces koji je povezan s kupovnim odlučivanjem. Ako je potrošač spoznao problem, on se uključuje u pretkupovno traženje informacija.
- Stalno traženje nije povezano sa specifičnom potrebom ili kupovinom. Ovaj proces nije povezan s namjerom o kupovini proizvoda ili usluge, nego s općim interesom potrošača za kakvu kategoriju proizvoda ili općenito znatiželju za prikupljanje specifičnih informacija.
- Interno traženje je prvi, osnovni oblik traženja informacija nakon spoznaje postojanja problema. U okviru psihičkog procesa potrošač pretražuje memoriju tražeći informacije povezane s konkretnim problemom i kupovnom situacijom. Prema Khanu (2007.) interno traženje je dovoljno u slučaju kada se radi o impulzivnoj kupovini, kupovini zbog lojalnosti te kod rutinske kupovine.
- Eksterno traženje se odnosi na proces dobivanja informacija iz eksternih izvora nakon što je potrošač ustanovio da informacije pohranjene u vlastitoj memoriji nisu dovoljne. Kako ovdje Khan (2007.) ističe, riječ je o kupovinama koje zahtijevaju visoku uključenost potrošača.

Utjecaj izvora ovisi o kategoriji proizvoda i kupčevim osobinama. Općenito govoreći potrošači većinu informacija o nekom proizvodu, ili usluzi, dobivaju iz komercijalnih izvora. Unatoč tome, najpouzdanije informacije dolaze iz osobnih izvora. Za potrošača su osobni izvori podataka mnogo vrijedniji od komercijalnih izvora (Munthiu, 2009.). Drugim riječima rečeno, kako su Kotler i Armstrong (2010.) istaknuli, rijetkost je da promotivna kampanja može biti toliko učinkovita, koliko jedan susjed može, koji kaže: 'Ovo je divan proizvod'.

Kako ističe Munthiu (2009.), što je veća vrijednost proizvoda ili usluge, a učestalost kupovine niža, to će potraga za informacijama biti temeljitija te će se koristiti više izvora informacija. Dakle, ako se radi o ekstenzivnom rješenju problema, za očekivati je kako će potrošač provesti temeljitiju pretragu dostupnih informacija.

Značajno za fazu traženja informaciju su determinante koje ju određuju, a to su: situacijske determinante, determinante proizvoda, determinante maloprodaje i determinante potrošača, koje Kesić (2006.) definira na sljedeći način:

- Situacijske determinante – su čimbenici povezani sa specifičnom situacijom, specifičnim vremenom i prostorom i u cijelosti su neovisni od obilježja potrošača, objekata i usluga koja se kupuje. Varijable koje se mogu smatrati situacijskim čimbenicima su: fizičko okruženje, društveno okruženje, vrijeme kupovine, cilj povezan s ponašanjem potrošača, prethodna stanja organizma i uvjeti kupovine.
- Determinanta proizvoda – broj i diferencijacija proizvoda determinirati će potrošačevo traženje i vrednovanje. Ako potrošač vjeruje da se obilježja proizvoda bitno razlikuju jedne do druge marke, traženje će zauzeti značajno mjesto u procesu odlučivanja. Drugo obilježje proizvoda je cijena. Visoke cijene proizvoda zahtijevaju veću angažiranost u traženju i uspoređivanju. Također stupanj rizika vezan uz određene kategorije proizvoda uvjetuje i obuhvat traženja.
- Determinante maloprodaje – mogućnost izbora maloprodajnog mjesta, udaljenost prodavaonice, ljubaznost osoblja, izbor proizvoda i sl. također će utjecati na vrijeme i obuhvat traženja. Percipiranje veće različitosti među prodavačima na malo rezultirati će većim obujmom traženja, dok će percipirana sličnost smanjiti broj i obuhvat traženja.
- Determinante potrošača – kako Kesić (2006.) navodi, za obujam traženja najznačajnija su sljedeća potrošačeva obilježja: znanje, uključenost, vjerovanja i stavovi te demografska obilježja.

Međutim, kako Dudovski (2013.) navodi, svaki pojedinac je drugačije uključen u proces traženja informacija. Ovisno o njihovom znanju o proizvodu, prethodnim iskustvom ili kupovinom, ili nekim informacijama iz vanjskih izvora, poput povratnih informacija drugih.

### **2.1.3. Vrednovanje alternativa**

U ovoj fazi, kako Dudovski (2013.) navodi, potrošač analizira sve prikupljene informacije te uspoređuje proizvode i usluge prema potrebama koje on ima. Osim osobnih motiva, u ovoj fazi se uzimaju u obzir i osobine kao što su: veličina, kvaliteta, marka i cijena. Stoga se smatra, kako je ova faza procesa donošenja odluke o kupovini najbitnija.

Vrednovanje alternativa provodi se preko vrednujućih kriterija koji su dio kognitivne strukture pojedinca. Vrednujući kriteriji označuju standarde i specifikacije kojima se koristi potrošač kao referentnim točkama uspoređivanja različitih proizvoda i maraka. Vrednujući kriteriji pod utjecajem su osobnih razlika i čimbenika okružja. U osnovi se proces odvija tako da se procesira jedna po jedna marka, uspoređujući njihova obilježja sa željenim obilježjima, pohranjenima u okviru vrednujućih kriterija. (Previšić, Ozretić Došen, 2007.)

U osnovi postoji manji broj vrednujućih kriterija kod kupovine svakodnevnih proizvoda, a veći broj pri kupovini trajnih i skupih proizvoda. Vrednujući kriteriji se mijenjaju tijekom vremena. Iako je nemoguće navesti sve vrednujuće kriterije, osnovni kriteriji koji se najčešće razmatraju u svim kategorijama su: cijena, marka proizvoda, zemlja porijekla i ključna obilježja za pojedine kategorije proizvoda. (Kesić, 2006.)

Prema Kesić (2006.) razlikujemo dva pristupa vrednovanju proizvoda, nekompenzacijsko pravilo odlučivanja i kompenzacijsko pravilo odlučivanja. Nekompenzacijsko odlučivanje se odnosi na pravilo kada jedno visokocijenjeno obilježje proizvoda ne može kompenzirati druga loša obilježja. Dok kod kompenzacijskog odlučivanja potrošači dopuštaju da pozitivno ocijenjena obilježja kompenziraju negativno ocijenjeno obilježje.

Kako su prepoznali Tenner i Raymond (2012.), tvrtke pokušavaju uvjeriti potrošače kako su kriteriji ocjenjivanja o kojima potrošač razmišlja, upravo snage njihovog proizvoda, ili usluge. Stoga je nerijetko da proizvođači ističu obilježja proizvoda, koje oni smatraju ključnima, kao vrednujuće kriterije. Zbog toga je njihova preporuka, kako treba dodati dodatne kriterije, kako bi se donijela bolja procjena proizvoda, ili usluge.

#### **2.1.4. Kupovina**

Kupnja je pretposljednja faza kupovnog procesa; označava pravni i/ili fizički prelazak proizvoda u vlasništvo kupca. No, i u toj fazi postoji razlika između rutinske kupnje i rješavanja problema. Kod rutinske kupnje potrošač kupuje, konzumira i pohranjuje proizvod i na tome se najčešće proces završava. Kod ponašanja potrošača koje označava rješenje problema, proces se nastavlja i nakon kupnje i konzumiranja proizvoda. (Previšić, Ozretić Došen, 2007.)

Prema Tauberu (1972.), razloge zašto ljudi kupuje možemo podijeliti u dvije skupine motiva, a to su osobni i društveni. Osobni motivi su: igranje uloge (majka, kućanica, zaposlena žena), različitost, zadovoljstvo, učenje o novim trendovima, fizička aktivnost, osjetilni stimulansi. S druge strane su društveni motivi, koji podrazumijevaju: društveno iskustvo izvan doma, komunikacija s drugim ljudima sličnih interesa, interakcija s članovima referentnih grupa, status i autoritet i ugođaj cjenjkanja.

Prema Kesić (2006.), za marketing je bitno razlikovati dvije vrste kupovine, rutinsku i impulzivnu. Kada se radi o rutinskoj kupovni proizvođači mogu za svoju marku diferencirati lojalne od nelojalnih potrošača i zatim primjenjivati različite marketinške strategije. S druge strane je impulzivna kupovina. Budući da impulzivna kupovina predstavlja značajan postotak ukupne kupovine, potrebno je uzeti u obzir njezine implikacije. Impulzivna kupovina se dijeli na: čistu impulzivnu kupovinu, sugeriranu impulzivnu kupovinu, podsjetnu impulzivnu kupovinu i planiranu impulzivnu kupovinu.

#### **2.1.5. Poslijekupovno ponašanje**

U poslijekupovnoj fazi najčešće dolazi do poslijekupovnog vrednovanja proizvoda. To je proces aktivne psihičke uključenosti u kojoj kupac vrednuje odabranu nasuprot svih ostali alternativa koje je mogao odabrati. Kao rezultat ovoga stanja javlja se misaona (kognitivna) disonanca kao nesklad očekivanog i dobivenog kupovinom proizvoda ili usluga. Iskustvo se kao rezultat procesa odlučivanja o kupovini povratnim vezama pohranjuje u memoriju, najčešće u područje vrednujući kriterija kao podloga za buduće odluke. (Kesić, 2006.)

Svakom proizvođaču je cilj smanjiti poslijekupovnu disonancu i zadržati potrošača. Smanjenje disonance postiže se na dva načina: smanjenjem očekivanja potrošača ili poboljšanjem obilježja proizvoda. Zadržavanje postojećih kupaca jedan je od prioritetnih zadataka. Stoga je potrebno pažljivo pratiti prigovore i žalbe potrošača te i redoviti rješavati, uvesti potpunu kontrolu



kvalitete, primjenjivati individualni pristup potrošaču, komunicirati realna očekivanja potrošača te osigurati servis i jamstva za proizvode. (Previšić, Ozretić Došen, 2007.)

Ovu fazu procesa odlučivanja o kupovini trgovci često zanemaruju, kao što i Dudovski (2013.) ističe, ova faza ima važnu ulogu iz razloga što utječe na buduće postupke odlučivanja potrošača. Ovo stajalište također zauzimaju Ofir i Simonson (2007.), koji govori kako je proces donošenja odluke o kupovini ponavljajući proces, a pozitivno iskustvo je od iznimnog značaja za smanjenje neizvjesnosti kada se odluka o kupovini istog proizvoda, ili usluge, bude opet donosila.

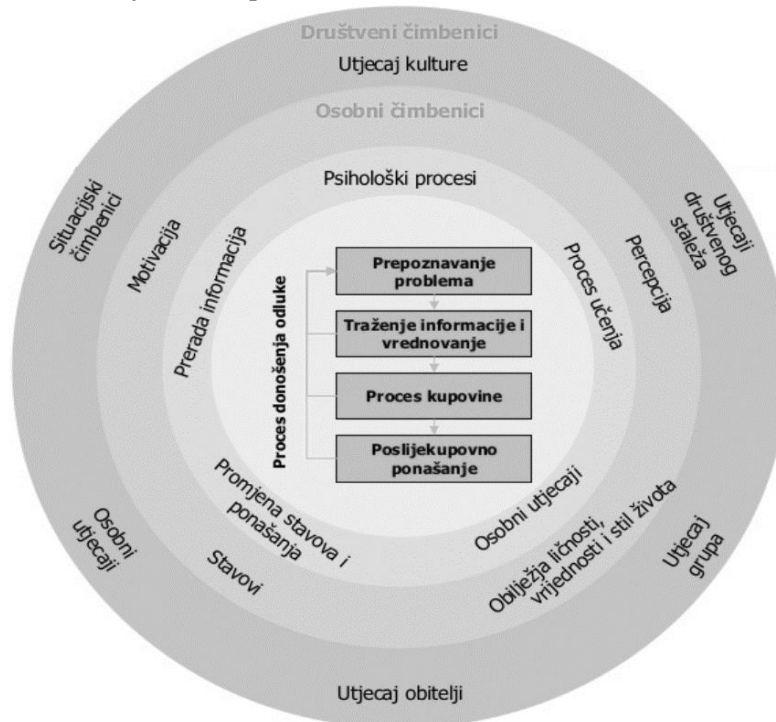
## **2.2. Čimbenici koji utječu na proces donošenja odluke o kupovini**

Kako navodi Ajzen (2008.), odluka o kupovini suočava potrošača s mnoštvom potencijalnih izazova, a kao najvažniji ističe problem strukturiranja, s obzirom na moguće ishode koje ovise o odluci, a koji se javlja prije donošenja odluke: spoznaja problema ili dostupnost novog proizvoda ili usluge, zatim prikupljanje podataka o alternativama, identificiranje mogućih budućih događaja i ostalih okolnosti koje su bitne za odluku o kupovini. Nakon što je problem strukturiran, potrošač mora obraditi prikupljene informacije, odabrati način djelovanja i primijeniti odgovarajuću odluku.

Prema Kesić (2006.), ponašanje kupaca je proces na koji reagira veliki broj čimbenika koji utječu jedan na drugi i konačno ponašanje kupaca. Većina literature ih svrstava u tri grupe i to su: osobni čimbenici, društveni čimbenici i psihološki procesi.

Na slici 2 prikazan je proces donošenja odluke o kupovini proizvoda ili usluge. Oko procesa navedeni su čimbenici koji utječu na donošenje odluke. Prema tome, radi li se o unutarnjim ili vanjskim čimbenicima, na slici su oni koji su unutarnji bliže središtu, a vanjski čimbenici udaljeniji od središta.

## 2. Utjecaj na proces donošenja odluke potrošača



Izvor: Loudon, D. L., & Della Bitta, A. J. (1984). Consumer behavior: Concepts and applications. McGraw-Hill Companies. Preuzeto iz: Kesić T. (1999). Ponašanje potrošača, Zagreb, ADECO

Detaljno proučavanje ponašanja potrošača vrlo je kompleksno budući da velik broj varijabli interaktivno reagira i utječe jedna na drugu, i konačno na ponašanje potrošača. Modeli ponašanja potrošača razvijeni su kao metoda da se ublaži kompleksnost i ponašanje učini razumljivijim i prihvatljivijim za širu publiku. Modeli predstavljaju pretpostavljeni skup varijabli i njihova međusobna djelovanja u procesu donošenja kupovne odluke. (Kesić, 2006.)

### 2.2.1. Društveni čimbenici

Na ponašanje potrošača utječe velik broj vanjskih čimbenika koji su klasificirani kao društveni čimbenici. Proces donošenja odluke o kupovini je pod utjecajem sljedećih grupa društvenih čimbenika (Kesić, 2006.):

- **Kultura** – utjecaj kulture obuhvaća širok spektar društvenih utjecaja, utjecaja jezika, društvenih vrijednosti, vjerovanja, predrasuda, itd. Koncentracija, globalizacija i internacionalizacija industrije potrošačkih proizvoda s jedne strane i rast mobilnih potrošača s druge strane, stvorio je podlogu za stvaranje globalne kulture.
- **Društveni stalež** – predstavlja skupinu ljudi koji dijele slične vrijednosti, interese i ponašanja. U većini društava staleže se mogu podijeliti na visoki, srednji i niski.

Determinante društvenog staleža su: dohodak, obrazovanje i znanje, osobne performanse, vrijednosna orijentacija i imovina i nasljeđe.

- Utjecaj društvenih grupa – rođenjem pojedinac postaje član grupe kao što su obitelj, društvo, kulture, itd. Prema Lewittu (1973.) pet osnovnih obilježja koje skupina ljudi mora ispuniti da bi se smatrala grupom je: zajednički cilj, razlikovanje uloga, vrijednosti i norme grupe, članstvo i komunikacija. Stoga društvene grupe možemo podijeliti na: primarne grupe u koje spadaju obitelj, rodbina, susjedi i slično, sekundarne u koje se ubrajaju poduzeće, klubovi, crkva i slično te referentne grupe. Prema Bennettu i Kassarianu (1972.) je referentna grupa ona koju pojedinac utvrđuje kao 'točku reference' u određivanju svog vlastitog suda, preferencija, uvjerenje i ponašanja.
- Obitelj – predstavlja temeljnu referentnu grupu, u kojoj pojedinac postaje članom svojim rođenjem, ima najveći utjecaj na njegovo ponašanje u ranoj mladosti. Uloge u obitelji su različite te prema tome članovi mogu imati jednu ili više uloga: inicijatori, utjecajni, odlučitelji, kupci i korisnici. Uloge uglavnom ovise o vrsti proizvoda, kompliciranosti odlučivanja, visini izdatka i namjeni proizvoda.
- Situacijski čimbenici – utječu na ponašanje pojedinca promjenom situacije u kojoj se donosi odluka o kupovini. U ove čimbenike ubrajamo fizičko okružno u kojem se odvija kupovina, društveno okružno, vrijeme kupovine, cilj kupovni i psihičko i fizičko stanje potrošača u vrijeme kupovine.

Poznavanje obilježja pojedinih grupa društvenih čimbenika je od iznimne važnosti za marketinške stručnjake i definiranje marketinške strategije.

### **2.2.2. Osobni čimbenici**

Postoji pet individualnih varijabli od posebnog su značenja za ponašanje potrošača. To su: motiv i motivacija; percepcija; stavovi; obilježja ličnosti, vrijednosti i stil života te znanje. Svaki kupac u proces donošenja odluke o kupovini ulazi s tri raspoloživa resursa, odnosno vremenom, novcem i sposobnošću prihvatanja i procesiranja informacija. Raspolaganje resursima potrošača je ograničeno i stoga je potrebno uložiti znatan napor u korištenju ovih resursa u procesu ponašanja potrošača. (Kesić, 2006.)

Postoje brojna istraživanja koja pokušavaju otkriti motive kupovine pojedinih proizvoda. Motiv se prema Kesić (2006.) definira kao trajna predispozicija koja usmjerava ponašanje k određenom cilju, a za potrebe marketinga motivi se dijele na racionalne i emocionalne. S druge

strana motivacija predstavlja proces pokretanja ljudskog organizma prema cilju te je onda određena stupnjem uključenosti kupca u proces kupovine.

Uključenost potrošača u proces donošenja odluke o kupovini, prema Tanner i Raymond (2012.), može se kretati od visoke, do niske uključenosti. Kada se radi o rutinskoj kupovini, često se donose odluke s niskom razinom uključenosti, pri tome se potrošači oslanjaju na informacije o proizvodima i uslugama koje su prikupili u prošlosti te ne doživljavaju rizik od pogreške prilikom kupovine. Također i kod impulzivne kupovine je prisutna niska razina uključenosti. S druge strane, kada se radi o kupovinama s visokom razinom uključenosti, riječ je o kupovini koja nosi visoki rizik, što je slučaj kod kupovine proizvoda ili usluga, čija je cijena visoka, ili su njihove karakteristike kompleksne. U istraživanju, kojeg su proveli Petty, Cacioppo i Schumann (1983.) na studentima preddiplomskog studija, došli su do zaključka, kako manipulacija argumentima ima jači utjecaj na pojedince koji su snažno uključeni, nego na one koji su imali nisku razinu uključenosti. Također je ustanovljeno, kako su oni koji preferiraju određeni proizvod imali veći utjecaj na pojedince s niskom uključenosti, nego na one s visokom razinom uključenosti.

Percepcija je proces kojim potrošači odabir, organiziraju i interpretiraju informaciju u značajnu sliku svijeta. Osnovno obilježje percepcije jest da se radi o selektivnom procesu koji se sastoji od sljedećih gaza: selektivne izloženosti, selektivne pažnje, selektivnog razumijevanja i selektivnog zadržavanja. Obzirom da je percepcija iznimno značajna za ponašanje potrošača i proces donošenja odluke, bitno je spomenuti i koncept subliminalne percepcije. Ovaj koncept se odnosi na primanje informacija iz okoliša bez svjesnog percipiranja od strane potrošača. Odnosno informacije su primljene ispod ili iznad pragova ljudske percepcije. (Previšić, Ozretić Došen, 2007.)

Stavovi predstavljaju spremnost pojedinca ka pozitivnoj ili negativnoj reakciji na pojedine objekte, usluge ili situacije. Oni predstavljaju relativno trajne predispozicije potrošača i stoga ih je teško mijenjati. Stoga marketinški stručnjaci moraju istraživati i razumjeti stavove potrošača te prema tome prilagoditi marketinšku strategiju. (Kesić, 2006.)

Obilježja ličnosti predstavljaju trajne osobnosti potrošača koje utječu na njegovo ponašanje na tržištu. Vrijednosti predstavljaju društveno prihvaćen način ponašanja, a osobne vrijednosti predstavljaju ponašanje u skladu s osobnim uvjerenjima. Stil života predstavlja aktivnosti, interese i mišljenja koja utječu na način trošenja vremena i novca pojedinca (Kesić, 2006.). Nalazi istraživanja, provedeni od Dholakia (1978.), govore kako razlika u uporabi marki mogu

objasniti teorijom ličnosti pod određenim uvjetima. Odnosno, istraživanje ukazuje na to, da su brandovi koji su zauzimali različite pozicije proizvoda privlačili različite tipove ličnosti.

Znanje se može definirati kao informacije pohranjene u memoriji potrošača. Stoga, kako Sharma (2013.) navodi, je za pokretanje i vođenje poslovanja bitno poznavanje potrošača i njegovog znanja, je na taj način se može utjecati na odluku o kupovini. Znanje potrošača pomaže u donošenju odluka zašto nešto kupiti, gdje nešto kupiti, kada kupiti. Znanje potrošača utječe na to koji je pravi proizvod za kupnju.

### **2.2.3. Psihološki procesi**

Kako bi marketinški stručnjaci mogli imati utjecaja na potrošača i način donošenja odluke, moraju poznavati proces prerade informacije i na koji način se odvijaju promjene stavova i ponašanja. Psihološki procesi obuhvaćaju (Kesić, 2006.):

1. Preradu informacija
2. Učenje,
3. promjenu stavova i ponašanja i
4. Komunikacija u grupi i osobne utjecaje.

Obzirom da se marketinškom komunikacijom pokušava utjecati i usmjeravati ponašanje potrošača, od iznimne je važnosti za marketinške stručnjake spoznaja na koji način potrošač prima, procesira i smisleno organizira i koristi dobivene informacije. Danas interaktivna komunikacija postaje dominantni instrument ponašanja potrošača, obzirom da omogućava dvosmjernu komunikaciju. Iako se to prvenstveno ističe na tržištu usluga i tržištu proizvoda poslovne potrošnje, interaktivna komunikacija se probija i na tržište osobne potrošnje. (Kesić, 2006.)

Učenje je proces prihvatanja novih sadržaja procesom komunikacije ili iskustva i pohranjivanja u trajnu memoriju. Stoga ako se želi izazvati promjena u ponašanju prethodno mora komunikacijom ili iskustvom pokrenuti proces učenja, koji će u konačnici dovesti do promjene stavova, mišljenja te konačno i ponašanja potrošača. Postoje tri temeljna oblika učenja: učenje uvjetovanjem, učenje prema modelu i učenje spoznajom. Svrha učenja je postizanje navike u kupnji i lojalnosti proizvodu i marki. (Previšić, Ozretić Došen, 2007.)

Prema Kesić (2006.) promjena stavova i ponašanja predstavlja krajnji cilj marketinških aktivnosti. Stoga, kako i Madichie (2012.) navodi, marketinški stručnjaci moraju razumjeti stavove potrošača u različitim okolnostima i osmisлити načine utjecaja na te stavove kako bi potrošači zauzeli pozitivniji stav prema proizvodima ili uslugama u ponudi.

Komunikacija u grupi i osobni utjecaji se odvijaju najčešće u primarnim grupama, u kojima se izdvaja jedan član na osnovi znanja, sposobnosti, obilježja ličnosti i slično te utječe na ponašanje drugih članova grupe. Osobni se utjecaj izražavaju komunikacijom u grupama, od čega imaju korist i ni koji utječu, ali i oni na koje se utječe.

### 2.3. Strategije upravljanja procesom donošenja odluke o kupovini

Prema Peteru i Olsonu (2010.) većina marketinških strategija ne može uspjeti bez utjecaja na ponašanje potrošača. Prema njima cilj većine marketinških strategija je, da održava ili povećaju prodaju određenog proizvoda ili usluge. To se obično postiže: a) povećanjem učestalosti kupnje postojećih kupaca, b) održavanje razine potražnje postojećih kupaca i povećanje broja novih kupaca, c) povećanje potražnje postojećih kupaca i povećanje broja novih kupaca. Stoga je ključno za razvijanje strategije razumjeti proces donošenja odluke i proces prihvatanja novog proizvoda.

#### 2.3.1. Proces prihvatanja novog proizvoda

Tradicionalni pogled na proces prihvatanja novog proizvoda marketinški stručnjaci tretiraju kao niz kognitivnih događaja koji obično praćen kupovinom. (Peter, Olson, 2010.)

##### 1. Prikaz modela procesa prihvatanja novog proizvoda

	ZNANJE	OSJEĆAJI	MOTIVACIJA → DJELOVANJE
<b>AIDA (Strong, 1925.)</b>	<i>Pažnja</i>	<i>Interes</i>	<i>Želja</i>
<b>DAGMAR (Colley, 1961.)</b>	<i>Svijest</i>	<i>Razumijevanje</i>	<i>Odluka</i>
<b>Lavidge &amp; Steiner (1961.)</b>	<i>Svijest</i>	<i>Sviđanje</i>	<i>Odluka</i>
<b>Wells i suradnici (1965.)</b>	<i>Percepcija</i>	<i>Razumijevanje</i>	<i>Uvjerenje</i>
	<b>KOGNITIVNA</b>	<b>AFEKTIVNA</b>	<b>BIHEVIORALNA</b>

Izvor (prerada): Egan, J. (2007). Marketing communications. Cengage Learning EMEA.

Kako Kenton (2018.) navodi, modeli prihvaćanja novoga proizvoda su prikaz kako marketinška komunikacija može utjecati na proces donošenja odluke, da li određeni proizvod, ili uslugu kupiti, ili ne. Modeli prikazuju korake u procesu učenja i odlučivanja, a koriste se kako bi se strukturirano postavili ciljevi marketinške komunikacije. Pri tome je bitno napomenuti nedostatak ovih modela, a to je da modeli ne predviđaju poslijekupovne procese (Wijaya, 2015.).

Prema Peteru i Olsonu (2010.) u fokusu marketinških stručnjaka prema ovom prikazu su kognitivne varijable (svjesnost, spoznaja, interes, procjena, itd.). Prema tome glavni zadatak marketinških stručnjaka je utjecati na kognitivne, afektivne i bihevioralne varijable i premješati potrošača kroz svaku fazu dok ne izvrši kupovinu. Iako je prethodni prikaz koristan, marketinški stručnjaci proces kupovine često gledaju i kao slijed ponašanja, stoga ulažu napore u osmišljavanju strategija kojima će izazvati određeni slijed događaja i potaknuti potrošače povećaju učestalost pojave istoga.

### 2.3.2. Strategije upravljanja procesom donošenja odluke o kupovini

Važno je spoznati kako je utjecanje na ponašanje potrošača od iznimne važnosti. Ako se kod potrošača promijene samo ono što misle i osjećaju, ali ništa ne učine, ne dolazi do razmjene, nema prodaje, niti se ostvaruje profit. (Peter, Olson, 2010.)

#### 2. Strategije utjecanja na ponašanje potrošača

Strategija	Opis strategije	Fokus strategije	Primjer strategije	Krajnji cilj strategije
Afektivna	Strategije usmjerene izazivanju afektivne reakcije potrošača	Potrošačeve emocije, raspoloženje, osjećaji vrijednosti	Klasično uvjetovanje emocija prema proizvodima	Utjecanje na ponašanje potrošača
Kognitivna	Strategije usmjerene izazivanju kognitivne reakcije potrošača	Potrošačevo znanje, mišljenje, vjerovanje.	Pružanje informacija i isticanje konkurentske prednosti	Utjecanje na ponašanje potrošača
Bihevioralna	Strategije usmjerene izazivanju bihevioralna reakcije potrošača	Potrošačevo ponašanje	Poboljšanja; modeliranje željenog ponašanja	Utjecanje na ponašanje potrošača
Kombinirana	Strategije usmjerene izazivanju višestrukih reakcija potrošača	Više od jednog gore navedenog	Informacije o prednostima proizvoda s emocionalnom vezom i popusti	Utjecanje na ponašanje potrošača

Izvor(prerada): Peter, J. P., Olson, J. C., (2010). Consumer behaviour and marketing strategy, McGraw-Hill

U prikazu se mogu vidjeti četiri strategije, kojima se prema Peteru i Olsonu (2010.) može utjecati na ponašanje potrošača:

- Elementi marketinškog miksa afektivne strategije su oblikovani na način da utječu na izazivanje afektivnih reakcija. Primjer ove strategije je Michelin koji je u svojim oglasima prikazivao bebe te na taj način potaknuo osjećaje topline i usmjerio pažnju na važnost sigurnosti djece u prometu.
- Kod kognitivne strategije, elementi marketinškog miksa su oblikovani da utječu na spoznaju potrošača kako bi utjecao na njegovo ponašanje. Primjer za ovu strategiju su katalozi koji sadrže dodatne informacije, koje njihovim korisnicima olakšava odabir.
- U trećoj strategiji su elementi marketinškog miksa usmjereni na vidljivo ponašanje potrošača, što ne znači da potrošači ne osjećaju, ili razmišljaju o ničemu prije nego što učine nešto. Nego prilikom donošenja odluka, neke su donesene automatski, ili s niskom razinom svjesnosti. Često je ponašanje potrošača rutinsko stoga su i strategije često prilagođene tomu. Primjer za to su kuponi ili prodajne promocije.
- Posljednja strategija podrazumijeva kombinaciju više prethodnih strategija. Primjer takve strategija je slika u boji, koja prikazuje igračku s dvoje djece kako se igraju, opis igračke, preporučenu dob, upute za sklapanje i cijenu. Ovakav oglas koristi više različitih strategija za utjecanje na ponašanje potrošača.

Može se zaključiti kako su marketinške strategije oblikovane na način da utječu na ponašanje potrošača. Stoga je ključno dobro razumijevanje ponašanja potrošača te odnosa među pojedinim elementima procesa prihvatanja proizvoda. (Peter, Olson, 2010.)

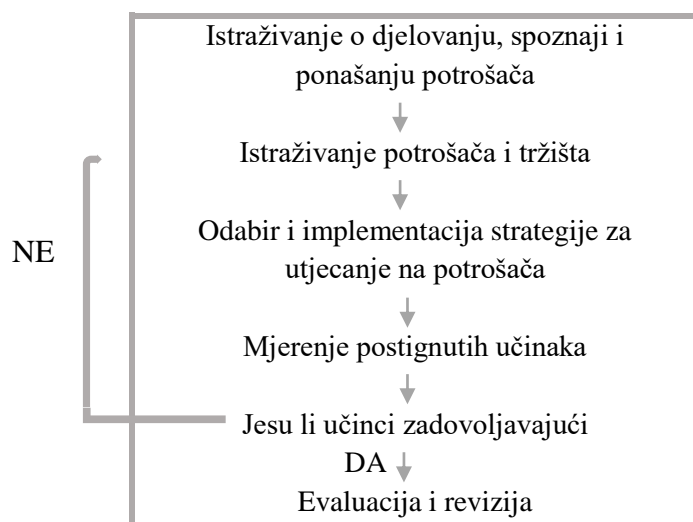
### **2.3.3. Provođenje strategije upravljanja procesom donošenja odluke o kupovini**

Kada se promatra marketinške strategije, najčešći cilj im je, ili zadržavanje trenutnog položaja, ili poboljšanje za određeni iznos postotnih poena u okvirima zadanog budžeta. Kako bi to ostvarili marketinški stručnjaci pokušavaju utjecati na djelovanje, spoznaju i ponašanje potrošača. Kako bi se utjecalo na te varijable svakog potrošača, provode se strategije koji imaju i dugoročne i kratkoročne učinke. (Peter, Olson, 2010.)



Kako bi marketinški stručnjaci, menadžeri, razvili učinkovitu marketinšku strategiju Peter i Olson (2010.) su prikazali generalizirani model koji prikazuje korake za razvijanja strategije kojom se utječe na ponašanje potrošača.

### 3. Koraci za izradu strategije utjecanja na ponašanje potrošača



Izvor (prerada): Peter, J. P., Olson, J. C., (2010). Consumer behaviour and marketing strategy, McGraw-Hill

Kako bi strategija bila uspješna marketinški stručnjaci prvo moraju znati što potrošači misle, osjećaju i čine po pitanju proizvode, prodavaonica i svega ostalog što se veže uz određeno poduzeće. Osim toga moraju poznavati i ponudu konkurencije. Za istraživanja potrebna za upoznavanje potrošača se mogu koristiti primarni i sekundarni izvori podataka, ovisno o mogućnostima i raspoloživosti podataka. (Peter, Olson, 2010.)

Sljedeći korak, prema Peteru i Olsonu (2010.), nakon što je prikupljeno dovoljno podataka, je analiza podataka prema reakcijama kupaca na tržištu koje se istražuje, ali i drugim potencijalnim tržištima. Cilj istraživanja je otkriti koji su razlozi da kupci na kupuju određeni proizvod, da li je nepoznavanje proizvoda, ili im se ne sviđa, ili ne znaju gdje kupiti, a također je moguće i da su zadovoljni i proizvodom kojeg nudi konkurencija. Ovisno o rezultatima se primjenjuje strategija pogodna za određene uvjete.

Ovisno o istraživanju tržišta i potrošača se implementira strategija. Strategija može uključivati sve ili samo neke od elemenata marketinškog miksa te može biti usmjerena na ostvarivanje i kratkoročni i srednjoročnih ciljeva. Na primjer promotivne aktivnosti imaju kratkoročne učinke

dok promjene na proizvodu, ili cjenovno pozicioniranje imaju dugoročne učinke. (Peter, Olson, 2010.)

Nakon implementacije, prema Peteru i Olsonu (2010.), slijedi mjerenje uspješnosti strategije. Potrebno je istražiti učinak strategije na ponašanje potrošača, da li je cilj postignut. U slučaju da zadani ciljevi nisu postignuti, potrebno je utvrditi uzrok neuspjeha strategije. Razlozi za neuspjeh strategije mogu biti razni, a neki od njih su: loše postavljene ciljevi, loša strategija, loša implementacija, loša mjerenja, neočekivane reakcije tržišta ili potrošača te kombinacija više razloga. Ako su pak postignuti zadani ciljevi, postoje dvije mogućnosti: jedna je da je strategija dobro provedena, a druga je da su ciljevi loše postavljene, da nisu bili objektivni. Stoga je bitno kontinuirano evaluirati strategiju.

Bez obzira koliko uspješna određena marketinška strategija bila, često postoji prostora za poboljšanja. Razrada i primjena strategija za utjecaj na ponašanje potrošača dinamičan je proces koji zahtijeva stalno praćenje postojećih strategija tvrtke i konkurenata, razvijanje novih strategija i predviđanje novih strategija konkurencije. (Peter, Olson, 2010.)

### 3. Uloga umjetne inteligencije u procesu kupovine

#### 3.1. Pojmovno određenje sustava preporuke

##### 3.1.1. Što su sustavi preporuke?

Sustavi preporuke su postali značajno istraživačko područje nakon prvog rada o kolaborativnom filtriranju, kojeg su sredinom 90-ih napisali Resnick, Iakovou, Sushak., Bergstrom i Riedl. Sustavi za preporuku, uglavnom pomažu korisnicima da pronađu sadržaj, proizvode ili usluge prikupljanjem i analizom prijedloga drugih korisnika, što podrazumijeva recenzije različitih korisnika. (Park, Kim H. K., Choi, Kim J. K., 2012.) Burke, Felfernig i Goker (2011.) sustav preporuke definiraju kao alat za interakciju s velikim i kompleksnim količinama informacija te takvi sustavi omogućavaju personaliziran pregled istih, pri tome izdvajajući prioritetne predmete kod kojih je veća vjerojatnost podudaranja s interesima korisnika.

Sustavi preporuke se razlikuju prema tome koju metodu za filtriranje podataka koristi, tako da se razlikuje: filtriranja koje se temelji na sadržaju, kolaborativno filtriranje i hibridno filtriranje.

- Filtriranje na temelju sadržaja – korisniku se preporučuju predmeti na temelju preferencija iz prošlosti. (Adomavicius, Tuzhilin, 2005.) Kod sustava preporuka koje filtriranje temelje na sadržaju, prvo sustav izrađuje korisnički profil koristeći korisnikove povratne informacije (*feedbackoove*) i ocjene predmeta. Zatim se korisnički profil uspoređuje s svojstvima predmeta te mu se preporučuju oni predmeti s kojima ima najviše dodirnih točaka. (Khusro, Ali, Ullah, 2016.)
- Kolaborativno filtriranje – spaja korisnike sa sličnim interesima te daje preporuke na temelju te baze podataka (Montaner, López, De La Rosa, 2003.) Prikuplja podatke o ocjenama korisnika za određene predmete te pronalazi slične uzorke ponašanja među korisnicima, korisnike koji daju slične ocjene, kako bi pronašao skupine ljudi koji imaju slične preferencije. (Khusro, Ali, Ullah, 2016.)
- Hibridno filtriranje – ovaj način filtriranja podrazumijeva kombinaciju više metoda filtriranja, a Burke (2002.) ih je kategorizirao prema sedam različitih oblika: ponderirani, promjenjivi (mijenja metodu ovisno o situaciji), mješoviti pristup, kombinacija svojstava, kaskadni, kombinirani (output jedne tehnike je input druge) i meta-razina. Ova metoda koristi više različitih metoda kako bi osiguralo preciznije podatke nego prethodne dvije.

Iako su sustavi preporuke proteklih godina jako razvili i napredovali postoji još mnoštvo otvorenih pitanja i izazova. Khusro, Ali i Ullah (2016.) su naveli sljedeće izazove za sustave preporuke:

- *Cold start problem* – ovaj problem se pojavljuje kada se pojavi novi korisnik ili predmet. U tom slučaju, niti se može predvidjeti preferencije novoga korisnika, niti se može ocijeniti novi proizvod. Iako i ovaj nedostatak se djelomično može riješiti upitnikom kojeg je prethodno potrebno ispuniti.
- Sinonimi – kada za jedan predmet postoji jedan ili više različitih naziva, ili kada jedan naziv ima više različitih značenja. U tom slučaju sustav preporuke ne može prepoznati razliku te tu značajnu ulogu igraju ocjene korisnika.
- *Shilling attacks* – ovdje se radi o slučaju kada netko upotrijebi sustav na način, da daje krive ocjene predmetima, kako bi im povisio ili snizio rejting.
- Privatnost – kako bi sustav preporuke postao bolji potrebno ga je opskrbljivati podacima, odnosno korisnici moraju unositi podatke o svom iskustvu. Takvi sustavi su podložni napadima te je potrebno izgraditi odnos povjerenje između sustava i korisnika.
- Ograničena analiza sadržaja i prespecificiranost – ovdje se radi prvenstveno o sustavima preporuke koji se temelje na analizi sadržaja. S jedne strane može se pojaviti manjak informacija o predmetu, a s druge strane može biti da ima previše informacija.
- *Grey sheep* – ovaj problem se odnosi na prvenstveno na kolaborativni sustav preporuke, kada se pojavi korisnik kojeg sa svojim preferencijama odstupa od svih skupina te ga nije moguće svrstati niti u jednu.
- Raspršenost – velika količina informacija o predmetima te nesklonost korisnika da ocjenjuje predmete čine matricu profila raspršenu što vodi do manje točnih preporuka.
- Skalabilnost – velika brzina rasta broja korisnika i predmeta znatno otežava rad sustava za preporuke, odnosno algoritmi postaju sve kompleksniji. Stoga je potrebno grupirati algoritme u manje klastere kako bi se izbjeglo pretraživanje čitave baze.
- Latentnost – nedostatak koji se pojavljuje kada se dodaju novi predmeti u sustav. Sustav za preporuke poznaje samo one predmete koji su već ocijenjeni stoga samo njih i preporučuje.
- Evaluacija i dostupnost online baza podataka - procjena sustava preporuka određuje između ostalog i njegovu kvalitetu. Odabir kriterija za evaluaciju i odabir odgovarajućih mjernih podataka ključni je problem u sustavima preporuka.

- Svijest o kontekstu – svijest o kontekstu predstavljaju sve odrednice prema kojoj je preporuka određena. Prema autorima rada ova mogućnost se očekuje kod nadolazećih sustava, što će preporuke učiniti znatno relevantnijima.

Unatoč značajnom napretku u razvoju sustava preporuke tijekom proteklog desetljeća, još uvijek postoje izazovi i poteškoće koji smanjuju relevantnost preporuka. Stoga su potrebna još dodatna poboljšanja kako bi sustavi preporuke bili primjenjiviji u širem razmjeru.

### 3.1.2. Povijesni razvoj sustava preporuke

Za bolje razumijevanje sustava preporuke prikazat će se povijesni razvoj istoga. Prema Venkatesanu i Thangaduraiu (2017.) korijeni sustava preporuke leže u „Usenet-u“, koji je pokrenut 1980. godine. Radi se o internet servisu koji je objave svojih korisnika klasificirao prema tematskim grupama.

#### 4. Povijesni pregled sustava preporuke

Do 1992.	Filtriranje sadržaja <ul style="list-style-type: none"> <li>- <i>An architecture for large scale information systems</i> (Gifford, 1985.)</li> <li>- <i>A rule-based message filtering system</i> (Pollock, 1988.)</li> <li>- <i>MAFIA: An active mail-filter agent for an intelligent document processing support</i> (Lutz, 1990.)</li> </ul>
1992. – 1998.	Xerox Palo Alto (1992.) <ul style="list-style-type: none"> <li>- Prvi sustav s kolaborativnim filtriranjem</li> </ul> GroupLens (1994.) <ul style="list-style-type: none"> <li>- Prvi sustav koji koristi ocjene</li> </ul> Movielens (1997.) <ul style="list-style-type: none"> <li>- Prvi sustav preporuke za filmove</li> </ul> <i>Empirical Analysis of Predictive Algorithms for Collaborative Filtering</i> (Brees, 1998.) <ul style="list-style-type: none"> <li>- Sustavno ocjenjivanje kolaborativnog filtriranja na temelju korisnika</li> </ul>
1999. – 2005.	Pandora započela projekt: Music Genome (2000.) Amazon predstavio sustav kolaborativnog filtriranja na temelju predmeta (zahtjev za patent je podnesen 1998., a izdan 2001.) Thomas Hofmann predstavio pLSA (1999.) primjenjuje sličnu metodu na kolaborativno filtriranje (2004.) <i>Evaluating collaborative filtering recommender systems</i> (Herlocker, 2004.)
2005. – 2009.	<i>Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions</i> (Tuzhilin, 2005.) Netflix Prize (natjecanje za poboljšanje Netflix-ovog sustava preporuke) <ul style="list-style-type: none"> <li>- Model latentnih faktora (SVD, RSVD, NSVD, SVD++)</li> <li>- Vremensko dinamično kolaborativno filtriranje</li> </ul>

ACM konferencija o sustavima preporuke u Minneapolisu, Minnesotai, SAD-u, 2007. godine

Digg (portal za vijesti) i Youtube testiraju sustav preporuke

---

Od 2010.	Sustavi preporuke koji razumiju kontekst Sustav preporuke za glazbu Sustavi preporuke i društvene mreže Informacijska heterogenost i fuzija u sustavima preporuke Ljudski proces donošenja odluka u sustavima preporuke Personalizacija u mobilnim aplikacijama Novosti i raznolikosti u sustavima preporuka Provjere usmjerene korisniku Facebook pokrenuo trenutnu personalizaciju (2010)
----------	---

Izvor: prerada prema: Venkatesan, M., & Thangadurai, K. (2017). History and Overview of the Recommender Systems. In Collaborative Filtering Using Data Mining and Analysis (pp. 74-99). IGI Global.

Kako su naveli Sharma i Singh (2016.) sustavi preporuke su razvijeni u skladu s naglim porastom mogućnosti odabira, kako bi se omogućio najprikladniji, ili najbolji odabir. Unatoč svemu postoje još brojni izazovi koje je potrebno prevladati. Stoga će biti potrebno uložiti još napora u razvijanje sustava preporuke, kako bi se uklonili nedostaci postojećih sustava i odgovorilo na izazove koji su pred njima.

## **3.2. Pojmovno određenje koncepta umjetne inteligencije**

### **3.2.1. Što je umjetna inteligencija?**

Godine 1956. John McCarthy je organizirao konferenciju, koja je okupljala brojne znanstvenike koji su bili zainteresirani za umjetnu inteligenciju. Posljedica konferencije je bio nastanak novog znanstvenog područja – umjetne inteligencije. McCarthy je skovao pojam umjetna inteligencija te ju definirao tada kao znanstvenu disciplinu koja se bavi izgradnjom računalnih sustava čije se ponašanje može tumačiti kao inteligentno, a od tada se umjetna inteligencija proširila na brojna druga područja. (Pan, 2016.)

Umjetna inteligenciju definiraju na više načina:

Marvin Minsky (MIT):

Znanost o tome kako postići da strojevi izvode zadatke koji bi, kada bi ih radio čovjek, iziskivali inteligenciju.

Patrick H. Winston (MIT):

Proučavanje postupaka koji mogućim čine percipiranje, rasuđivanja i reagiranje.

Elain Rich (Univesity of Texas, Austin):

Umjetna inteligencija bavi se izučavanjem kako računalo učiniti sposobnim da obavlja poslove koji u ovom času ljudi obavljaju bolje.

Eugen Charniak (Brown University):

Proučavanje mentalnih svojstava kroz uporabu računalnih modela.

Obzirom da ne postoji jedinstvena definicija umjetne inteligencije, Russel i Norvig (2016.) su klasificirali definicije te pokušali sistematizirati iste.. Njihova matrica definira umjetnu inteligenciju kroz dvije dimenzije. S jedne strane imamo misaone procese, odnosno način zaključivanja, a s druge ponašanje:

<p>Razmišljati ljudski</p> <p>“Uzbudljivi novi pokušaj da se omogući razmišljanje računalima. . . strojevi s umovima, u punom i doslovnom smislu.”(Haugeland, 1985.)</p> <p>Automatizacija aktivnosti koje asociramo s ljudskim razmišljanjem, poput donošenja odluka, rješavanja problema, učenja. . . ” (Bellman, 1978.)</p>	<p>Razmišljati racionalno</p> <p>Proučavanje mentalnih svojstava kroz uporabu računalnih modela.” (Charniak i McDermott, 1985.)</p> <p>“Proučavanje postupaka koji mogućim čine percipiranje, rasuđivanje i reagiranje.” (Winston, 1992.)</p>
<p>Ponašati se ljudski</p> <p>“Proces stvaranja strojeva koji obavljaju funkcije koje zahtijevaju inteligenciju koju imaju ljudi” (Kurzweil, 1990.)</p> <p>“Proučavanje kako učiniti da računala rade stvari u kojima su, trenutno, ljudi bolji” (Rich i Knight, 1991.)</p>	<p>Ponašati se racionalno</p> <p>“Polje rada koje želi objasniti i emulirati inteligentno ponašanje u smislu računalnih procesa” (Schalkoff, 1990.)</p> <p>“Grana računalnih znanosti koja se bavi automatizacijom inteligentnog ponašanja” (Luger i Stubblefield, 1993.)</p>

Navedeno je osam definicija, na vrhu su definicije koje se vežu uz misaoni proces, a na dnu one koje se vežu uz ponašanje. Lijevo su definicije koje mjere uspješnost sustava u usporedbi s čovjekom, a s desne strane se mjeri uspješnost prema idealiziranom modelu. (Russell, Norvig, 2016.)

Kako bi odredio da li strojevi mogu misliti, Alan Turing je 1950. godine u svome radu, *Computing machinery and intelligence* (Turing, 2009.), predložio test, danas poznat pod nazivom Turingov test. Test pretpostavlja da prikladan sudac, tj. čovjek, ne može prepoznati u

razgovoru da li razgovara s drugim čovjekom ili s računalom. Stoga je Turing predložio protokol kako provesti taj test: konverzacija se odvija u tekstualnom obliku (teleprinter), na taj način bi se provjeravao samo način tekstualnog razmišljanja, bez da se čovjek (sudac) vidi s kim komunicira. Turingov test je potaknuo brojne znanstvenike na razvijanje programa koji bi bili u stanju proći njegov test. (Singbo, 2009.)

Digitalizacija je imala znatan utjecaj na društvo, promijenila je načine života u potpunosti. Prema radu Makridakisa (2017.) koji govori umjetnoj inteligenciji i promjenama koje ona nosi, revolucija umjetne inteligencije (*AI Revolution*) će se dogoditi unutar idućih 20 godine, a njen utjecaj na društvo će biti veći nego utjecaj i industrijske i digitalne revolucije zajedno, ali nije siguran hoće li dovesti do utopije ili distopije. Također prema članku Agrawala, Gansa i Goldfarba (2017.), objavljenog u Harvard Business Reviewu, teško je predvidjeti kakve će posljedice donijeti umjetna inteligencija. Oni predviđaju dvije mogućnosti: s jedne strane kod predviđanja u donošenju odluka, strojevi će zamijeniti ljude, a s druge strane strojevi će biti dopuna, potpora ljudskom predviđanju. Bilo kako bilo, prema njima će to povećati potražnju tržišta za 'donošenjem odluka', tako da će se na taj način otvoriti nove prilike za vježbanje i usavršavanje ljudskog prosuđivanja.

### 3.2.2. Povijesni razvoj umjetne inteligencije

Za bolje razumijevanje umjetne inteligencije prikazat će se povijesni razvoj iste. Prema pregledu literature od Gupta-e (2017.) povijesni razvoj umjetne inteligencije tokom 19. stoljeća je bio ovakav:

#### 5. Povijesni pregled razvoja umjetne inteligencije

1921.	– drama „ <i>Rossum's University Robots (R.U.R.)</i> “, češkog pisca Karel Čapeka izvedena je u Londonu te je to bila prva upotreba riječi robot u engleskom jeziku.
1945.	– Isaac Asimov bivši profesor Bostonskog sveučilišta, tvorac pojma-robotika.
1950.	– Turingov test od Alana Turinga za provjeru inteligencije. Claude Shannon je objavio rad kako programirati računalo da igra šah.
1956.	– John McCarthy stvorio naziv- umjetna inteligencija.
1958.	– John McCarthy izumio LISP programski jezik za umjetnu inteligenciju.
1964.	– Danny Bobrow (MIT) rad je dokazao da računala mogu razumjeti dovoljno da rješavaju algebarske probleme ispravno.
1979.	– napravljeno prvo autonomno vozilo kojim upravlja računalo – <i>Stanford Cart</i>



1984.	– Daniel Dennet, američki filozof, raspravlja o logici prvoga reda te kako je to povezano s poteškoćama koje se pojavljuju stvaranjem robota koji imaju 'zdrav razum'.
1990.	– značajni napredci u svim područjima umjetne inteligencije: <ul style="list-style-type: none"> <li>• Značajan napredak u strojnom učenju</li> <li>• Rasuđivanje temeljeno na slučaju</li> <li>• <i>Multi-agent planning</i></li> <li>• Izrada rasporeda</li> <li>• Rudarenje podataka, web pretraživač</li> <li>• Razumijevanje jezika i prevođenje</li> <li>• Vizualizacija i virtualna stvarnost</li> <li>• Igrice</li> </ul>
1997.	– <i>Deep Blue</i> , program za igranje šaha, je pobijedio prvaka svijeta u šahu-Garryja Kasparova.
2000.	– interaktivni roboti postaju dostupni svima. MIT je predstavio robota s licem, imena Kismet, koji može izražavati emocije.

Izvor (prerada): Gupta, N., 2017, A Literature Survey on Artificial Intelligence, INTERNATIONAL JOURNAL OF ENGINEERING RESEARCH & TECHNOLOGY (IJERT) ICPCN – 2017 (Volume 5 – Issue 19)

Iako je umjetna inteligencija relativno mlado znanstveno područje, napredak u razvoju je priličan. Od nastanka tog znanstvenog područja 50-ih godina prošlog stoljeća do danas, dogodio se veliki iskorak po pitanju razvoja umjetne inteligencije, ali bitno je napomenuti kako razvoj umjetne inteligencije još uvijek na počecima. Prema Russelu i Norvigu (2016.), proteklih 60 godina glavni fokus, po pitanju umjetne inteligencije, je bio na algoritmu, ali nekoliko novijih radova govori, kako će veći problem biti nedostatak podataka. Stoga je ključno, za razvijanje umjetne inteligencije u budućnosti, količina podataka koju će imati na raspolaganju, a ne algoritam.

### 3.3. Pregled istraživanja uloge umjetne inteligencije u sustavima preporuke

Istraživanje koje su proveli Gabrani, Sabharwal i Singh (2017.), proučava sustave preporuke koji se temelje na umjetnoj inteligenciji. Istražili su nedostatke pojedinih sustava preporuke i mogućnosti pojedinih tehnika umjetne inteligencije, koje bi mogle riješiti nedostatke postojećih sustava preporuke. Različite tehnike umjetne inteligencije, kao : *fuzzy logic*, *artificial neural networks*, *artificial immune systems*, *swarm intelligence* i *evolutionary computing* imaju sposobnost učenja, prosuđivanja, planiranja, stvaranja znanja, prepoznavanje jezika, percepcije, predviđanja te sposobnost manipulacije podataka. (Engelbrecht, 2007.) Zbog tih mogućnosti se upotrebljava umjetna inteligencija kako bi se unaprijedili sustavi preporuke.

## 6. Tehnike umjetne inteligencije

Fuzzy logic	Koristi više varijabli te se upotrebljava kod analize podataka, prepoznavanja uzorka i procesa donošenja odluka.
Artificial neural networks	Pogodna tehnika za učenje, memoriranje i modeliranje nelinearnih vrijednosti. Može se upotrijebiti i za procjenjivanje odnosa između ulaznih podataka.
Artificial immune systems	Ova tehnika je nadahnuta strukturom i sustavom imunološkim sustavom. Primjenjiva tehnika u promjenjivom okruženju. Ova tehnika se koristi za klasifikaciju, izrade rasporeda, grupiranje podataka, rudarenje web-a, prepoznavanje uzorka i sigurnost.
Swarm intelligence	Ovo je tehnika bioloških organizama koja je nelinearna, decentralizirana i vrlo učinkovita za određivanje optimalnog rješenja. Ovaj sustav se koristi za pronalazak sličnih korisnika i njihovo grupiranje.
Evolutionary computing	Ova tehnika se temelji na darvinističkom principu biološke evolucije, nudi učinkovito rješenje za optimizaciju problema i približavanje problema u dinamičnom okruženju. Postoji nekoliko varijanti: <i>genetic programming</i> , <i>genetic algorithms</i> , <i>evolutionary programming</i> i <i>evolutionary strategies</i> . Ovi algoritmi se u sustavima za preporuke uglavnom koriste zbog njihove robusnosti kada dolazi do promjena.

Izvor (prerada): Gabrani, G., Sabharwal, S., & Singh, V. K. (2016, November). Artificial Intelligence Based Recommender Systems: A Survey. In International Conference on Advances in Computing and Data Sciences (pp. 50-59). Springer, Singapore.

Kako se može uočiti u prethodnoj tablici, svaka tehnika umjetne inteligencije je namijenjena za jednu, ili više poteškoća, ali nikako sve. Iako svaka od tehnike umjetne inteligencije znatno unapređuje sustave preporuke, svaka tehnika unapređuje određeni segment sustava preporuke. Stoga su potrebna daljnja istraživanja kako bi se postigla potpuna koherencija za rješavanje izazova sustava preporuke.

Prema istraživanju koje su proveli Gabrani, Sabharwal i Singh (2017.), o sustavima za preporuke koji se temelje na umjetnoj inteligenciji, skorašnji takvi sustavi su:

- Hibridni sustav preporuke koji se temelji na *fuzzy set-u*, rad je objavljen pod nazivom: „*A hybrid fuzzy-based personalized recommender system for telecom products/services*“, od autora Zhang, Z., Lin, H., Liu, K., Wu, D., Zhang, G., & Lu, J. iz 2013. godine
- Hibridni sustav preporuka koji se temelji na *fuzzy set-u*, rad je objavljen pod nazivom: „*A Googlewave-based fuzzy recommender system to disseminate information in*

*University Digital Libraries 2.0.*“ od autora: Serrano-Guerrero, J., Herrera-Viedma, E., Olivas, J.A., Cerezo, A., Romero, iz 2011. godine.

- Kolaborativni sustav filtriranja koji se temelji na *artificial immune system-u*, rad je objavljen pod nazivom: „*Applying artificial immune systems to collaborative filtering for movie recommendation*“, od autora Chen, M.H., Teng, C.H., Chang, iz 2015. godine.
- Hibridni sustav preporuke koji se temelji na *swarm intelligence-u*, rad je objavljen pod nazivom: „*Trust based recommender system using ant colony for trust computation*“, od autora Bedi, P., Sharma, iz 2012. godine.
- Sustav preporuke pod nazivom: „*A personalized auxiliary material recommendation system based on learning style on Facebook applying an artificial beecolony algorithm*“, od autora Hsu, C.C., Chen, H.C., Huang, K.K., Huang iz 2012. godine.
- Hibridni sustav preporuke koji se temelji na *genetic algorithm-u*, rad je objavljen pod nazivom: „*A recommender system using GA K-means clustering in an online shopping market*“, od autora im, K.J., Ahn, H., iz 2008. godine.
- Hibridni sustav preporuke koji se temelji na *fuzzy-genetic* pristupu, rad je objavljen pod nazivom: „*Fuzzy-genetic approach to recommender systems based on a novel hybrid user model*“, od autora Al-Shamri, M.Y.H., Bharadwaj, K.K., iz 2008. godine.
- Sustav preporuka temeljen na *genetic algorithm-u*, rad je objavljen pod nazivom: „*Twitter-based recommender system to address cold-start: a genetic algorithm based trust modelling and probabilistic sentiment analysis*“, od autora Alahmadi, D.H., Zeng, X.-J., iz 2015. godine.

Međutim potreban je dodatni napor i daljnji razvoj umjetne inteligencije kako bi se riješili svi nedostaci sustava za preporuku te kako bi se podigla učinkovitost u davanju relevantnih preporuka. (Gabrani, Sabharwal i Singh, 2017.) Unatoč tomu, što su sustavi preporuke već danas od iznimne koristi, jer znatno olakšavaju pretragu velikih količina informacija, za očekivati je kako će implementacija umjetne inteligencije dodatno podići razinu korisnost i primjenjivosti istih. Samim time će implementacija umjetne inteligencije u sustave preporuke znatno utjecati i na proces donošenja odluke o kupovini.

### **3.4. Utjecaj umjetne inteligencije na proces donošenja odluke o kupovini**

Umjetna inteligencija privlači pozornost sve više različitih područja djelovanja, njena primjenjivost je velika te se očekuje još dodatno širenje. Zbog mogućnosti koje već nudi, ali i potencijala kojeg ima postaje sve zanimljivija i u znanstvenim krugovima. Obzirom da je teško

predvidjeti kakve će sve promjene donijeti, teško je davati i konkretne zaključke kakav će utjecaj imati na društvo.

Umjetna inteligencija već danas igra znatnu ulogu prateći ponašanje i reakcije potrošača na internetu i društvenim mrežama. (Nadimpalli, 2017.) Jedna od posljedica toga je da potrošači lako pronalaze predmete od njihovog interesa te im se kroz različite oglase javljaju ponude vezane za isto. Iako se radi o jako kompleksnim procesima, praćenje reakcija, ponašanja potrošača i spremanje podataka, sve se to odvija u pozadini te ne ometa potrošače dok koriste internet. Unatoč poznavanja koncepta umjetne inteligencije, zbog njene kompleksnosti potrošači osjećaju određenu razinu rizika. Prema istraživanju Grewala i suradnika (2017.), koji su proveli međunarodno anketno istraživanje, utvrđeno je da od šezdeset i šest posto međunarodnih potrošača, njih osamnaest reklo da o umjetnoj inteligenciji zna mnogo, četrdeset i osam posto zna malo, a preostalih trideset do četrdeset posto nije odgovorilo ništa o toj temi. Iako ovi rezultati upućuju, da ogroman postotak potrošača ima znanje što se tiče umjetne inteligencije, zapravo većina njih nije uopće prepoznavala njene najosnovnije sposobnosti, kao što su rješavanje problema i učenje. Drugo je istraživanje pokazalo da samo trideset četiri posto potrošača koji su sudjelovali ima ideju o izloženosti umjetnoj inteligenciji u svojim svakodnevnim aktivnostima. (Nadimpalli, 2017.) Unatoč svemu, bitno je napomenuti kako većina dobro informiranih potrošača na umjetnu inteligenciju gleda pozitivno. (Kristin, 2017.) Smatraju da će im uštedjeti vrijeme i omogućiti poboljšani pristup relevantnim informacijama. (Kaplan, 2017.) Osim toga, smatraju da će donijeti i uštedu novca, ali i pojednostavljenje donošenja odluke o kupovini te sigurnost.

U konačnici svi potrošači uvijek traže praktičnost i osjećaj fleksibilnosti. Prisutnost umjetne inteligencije u svijetu omogućuje ljudima da žive svoje snove, jer mogu obavljati svoje zadatke iz udobnosti svojih domova. Promatrajući aspekte kupovine, potrošači su u mogućnosti provesti dugo i opširno istraživanje o potrebnim materijalima, pa čak i usporediti cijene i osvrte kako bi im kupili najprikladniji proizvod, što u konačnici pospješuje i potrošačku inteligenciju. (Michael, 2015.)

Posljedica tehnološkog razvoja je i nastanak takozvanog algoritamskog marketinga, koji je prema Katsovu (2017.) definiran kao marketinški proces, koji je automatiziran do te mjere da se njime može upravljati postavljanjem poslovnog cilja u marketinški software sustav. Primjer algoritamskog marketinga navodi i Gentsch (2017.) u svojoj knjizi, on opisuje kako je i put potrošača prilikom kupovine uporište za razvijanje strategije te da pruža dragocjene

informacije. Takozvani *customer journey*, iliti potrošačevo putovanje odvija se kroz faze, kojih je šest: prepoznavanje potrebe, istraživanje, dobivanje ponuda, pregovori i kupovina, poslijekupovno ponašanje i *word-of-mouth* komunikacija. Prijelazi između faza, dodirne točke, su polazišne točke, gdje se dobivaju korisne informacije koje se analiziraju. Na temelju tih informacija se mogu odrediti predviđanja za buduće *customer-journy-je*. Prednost takvih podataka je njihova neutralnost i objektivnost. Velika poduzeća, kao što su Apple, Google, Facebook i Amazon potvrđuju koliko su za uspješnost tvrtke bitni količina, kvaliteta i raznolikost takvih podataka. Također, kako Gentsch (2017.) ističe, trenutno se velika poduzeća bore, tko će razviti boljeg digitalnog osobnog asistenta, smatra kako će uobičajeno pretraživanje, kao na primjer Google tražilica, nestati te da će tu ulogu preuzeti osobni asistenti. Stoga će se proces kupovine ubuduće odvijati verbalno uz pomoći digitalnih osobnih asistenata.

## **4. Kvalitativno istraživanje o ulozi umjetne inteligencije u procesu donošenja odluke o kupovini**

### **4.1. Predmet i cilj istraživanja**

Prethodna poglavlja su bila usmjerena na pojašnjenje teorijskog okvira koji čini bazu istraživanja. Pojašnjen je i definiran proces donošenja odluke o kupovini, tj. pojedine faze procesa te su definirani čimbenici koji utječu na pojedine faze procesa i strategije upravljanja procesom donošenja odluke. Osim toga definiran je i koncept umjetne inteligencije i sustava preporuke, prikazan je njihov razvoj te njihov međusobni odnos. Obzirom na sve veću prisutnost suvremene tehnologije i umjetno inteligentnih sustava u svakodnevnom životu, njihova uloga postaje sve izraženija u potrošačevom ponašanju. U tom smislu, cilj je definirati ulogu umjetne inteligencije u procesu donošenja odluke o kupovini. Odnosno drugim riječima, istražiti će se na koje načine umjetno inteligentni sustavi mogu utjecati na proces donošenja odluke o kupovini.

### **4.2. Metodologija istraživanja**

Kako navode Tkalac Verčić, Sinčić Ćorić i Pološki Vokić (2013.), svrha kvalitativnog istraživanja je dublji uvid i razumijevanje nekog problema, također ističu kako je primarni interes proces a ne rezultati ili zaključci. Stoga, u svrhu bolje razumijevanja i uvida u problem, u ovom radu će biti primijenjena istraživačka metoda studija slučaja, na primjeru umjetno inteligentnog sustava Amazon Alexa. Na taj način se želi dati uvid u to koja je uloga umjetne inteligencije u procesu donošenja odluke o kupovini. Potrebne informacije će biti prikupljene prvenstveno s internet stranica Amazona i njegovih podružnica. Osim sekundarnih podataka, koji su dostupni na internetu, prikupit će se i primarni podatci su svrhu boljeg razumijevanja, a njih će se prikupiti uz pomoć provođenja dubinskih intervju s korisnicima proizvoda i usluga Amazona. Dubinski intervju će se provesti s osobama koje su koristile Alexa-u u Sjedinjenim Američkim Državama, obzirom da tamo Alexa ima najvišu razinu funkcionalnosti. Na temelju prikupljenih podataka i dubinskih intervju će se u raspravi dati uvid o ulozi umjetne inteligencije u procesu donošenja odluke o kupovini, obzirom na učestalost korištenja Alexa-e te s obzirom na donošenje odluke o proizvodima koji zahtijevaju različite razine uključenosti korisnika.

### 4.3. Rezultati istraživanja

#### 4.3.1. O kompaniji

Amazon.com, Inc., je puni naziv poduzeća koje je poznato pod imenom Amazon, stoga će se u daljnjem tekstu upotrebljavati samo Amazon. Riječ je o multinacionalnoj kompaniji, koja ja od nekadašnje online knjižnice i internet trgovine, postala jedna od značajnijih tehnoloških kompanija svijeta. Glavno sjedište se nalazi u Seattleu, Washingtonu, a njihov fokus je online prodaja, računalni oblak (*cloud computing*), digitalni *streaming* i umjetna inteligencija. Također pripada grupaciji *Big Four*, koja okuplja najznačajnije tehnološke kompanije današnjice, a uz Amazon to su: Google, Apple i Facebook. (Wikipedija, 2019.)

Godine 1994. Jeff Bezos je osnovao tvrtku u Washingtonu, pod nazivom Cadabra, Inc, koju je kasnije preimenovao u Amazon.com, Inc. Prema objavi Sarkara (2018.), naziv je odabrao zbog toga što je 'egzotičan i drugačiji', a kako je Amazona najveća rijeka, planirao je da i njegova prodavaonica bude najveća. Isprva se Bezos odlučio za online prodavaonicu knjiga, iz razloga što se knjige ne kvare, nema troškova razvoja, a diferenciraju se jedna od druge, jer je svaka jedinstvena. Već 1997. godine Amazon je izašao na burzu, a 1999. godine je pokušao ući u izdavačku djelatnost.

Danas je Amazonov asortiman (*Amazon Basics*) iznimno širok, nude predmete iz različitih kategorija: odjeću, proizvode za bebe, potrošačku elektroniku, kozmetičke proizvode, gurmansku hranu, namirnice, predmete za osobnu njegu i zdravlje, pribor industrijske i znanstvene namjene, kuhinjske predmete, nakit, satove, opremu za održavanje travnjaka i vrta, glazbene instrumente, sportsku opremu, alate, automobilske predmete, igračke i igre. Također je bitno istaknuti kako Amazon u svom vlasništvu ima veliki broj podružnica, koje proizvode različite proizvode i nude brojne usluge. Osim što nude brojne proizvode, Amazon u ponudi ima i brojne usluge, uključujući: AmazonFresh, Amazon Prime, Amazon Web Services, alexa, Appstore, Amazon Drive, Echo, Kindle, Fire tablets, Fire TV, Video, Kindle Store, Music, Music Unlimited, Amazon Digital Game Store, Amazon Studios i Amazon Wireless. (Sarkar, 2018.) Prema Business Insider-u (2019.) Ukupno Amazon u svom vlasništvu ima 41 podružnicu i marku.

Jedna od podružnica Amazona je i Alexa Internet, oni se bave prikupljanjem podataka o ponašanju korisnika na internetu, a prikupljeni podatci se prosljeđuju na web stranicu Alexa, gdje se analiziraju. Jedna od poznatijih usluga je *Alexa Traffic Rank*, ili samo *Alexa Rank*, riječ

je rangiranju web stranica, odnosno služi za provjeru popularnosti određene stranice. (Wikipedija, 2019.) Osim rangiranja, nudi i druge alate, koji će biti prikazani u daljnjem tekstu.

Prema Market.us-u (2019.), Amazon dnevno proda oko 1,6 milijuna predmeta. S Amazonom surađuje 1,9 milijuna malih i srednjih poduzetnika, *content creators* i *developers* u SAD-u. Amazonov događaj godine- *Prime Day*, nadmašio je prodaju *Cyber Mondayja* i *Black Fridayja* zajedno (prema CNBC-u je prodano preko 175 milijuna predmeta). Iako i ovi pokazatelji ukazuju na iznimne uspjehe i veličinu poslovanja Amazona, u Amazonu nastavljaju sa širenjem i unapređenjem svoga poslovanja.

#### **4.3.2. Uloga Amazona i Alexa-e u procesu donošenja odluke o kupovini**

Obzirom da proces donošenja odluke o kupovini nije linearan, tj. potrošači proces kupovini ne moraju započeti u prvoj fazi, spoznaja potrebe, potrebno je razviti marketinšku strategiju koja će potrošača moći pridobiti, neovisno u kojoj fazi započeo proces. Stoga su u Amazonu razvili niz alata, uz pomoć kojih se može upravljati procesom donošenja odluke o kupovini. Alexa Internet, podružnica Amazona, razvija alate koji služe za prikupljanje podataka o ponašanju pri pretraživanju interneta te ih analizira i pohranjuje. Kako i sami navode na svojoj stranici, njihov cilj je isporučivati egzaktno implikacije, koje će njihovim korisnicima biti korisni u ostvarivanju mjerljivih rezultata poslovanja. Pored toga, Amazon je razvio i Alexa-u kućnog asistenta, koji objedinjuje nekoliko funkcionalnosti te kojim se upravlja pomoću glasovnih naredbi. Osim navedenoga bitno je istaknuti i Amazonovu marku *Amazon Basics*, koja pokriva široki dio asortimana različitih kategorija. U nastavku su prikazani navedeni elementi te na koji način oni utječu na proces donošenja odluke o kupovini

##### **4.3.2.1. Alexa Internet**

Kako je već navedeno prije, Alexa Internet je podružnica Amazon.com-a. Oni se bave prikupljanjem podataka o internet prometu te analiziraju ga kako bi svojim korisnicima davali savjete i upute kako prilagoditi svoj nastup na internetu da postane učinkovitiji. Tvrtka je osnovana 1996. godine, a 1999. godine ju je Amazon otkupio (Wikipedia, 2019.). U nastavku je prikazano kako iz pomoć Alexa Internet-a upravljati pojedinom fazom procesa donošenja odluke o kupovini.

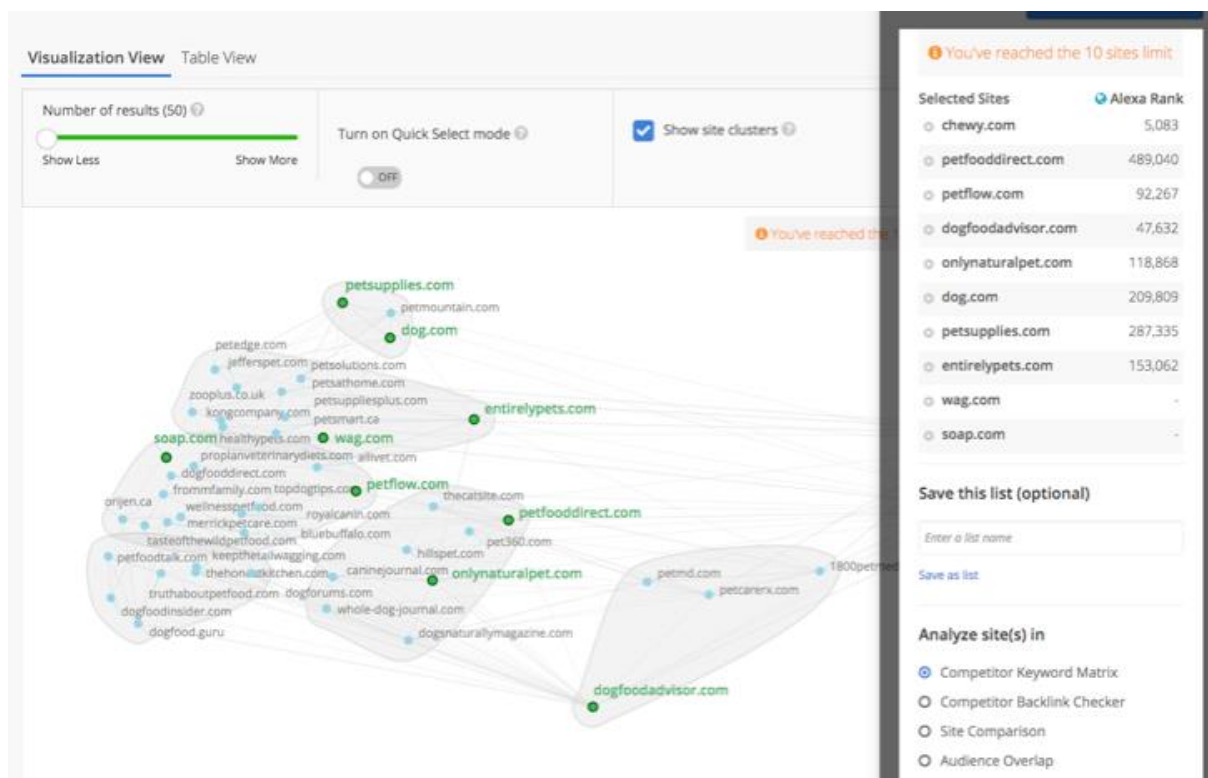


#### 4.3.2.1.1. Uloga Alexa Internet-a u fazi spoznaje potrebe

Proces donošenja odluke o kupovini započinje spoznajom potrebe. Potrošač prepoznaje nedostatak, tj. nekakav problem koji želi riješiti. U tom trenutku potrošač može, ali ne mora znati kako će izgledati rješenje njegova problema. Postoji mogućnost da znaju kako će izgledati njihovo rješenje, ali nisu sigurni koja će marka, proizvod, usluga pružiti najbolje rješenje.

Kako bi se privukla pažnja potrošača, potrebno je razviti sadržaj i plasirati ga na način da doprije do potrošača. Potrošač sadržaj mora povezati sa svojim problemom te prepoznati ga kao rješenje. Osim sadržaja, potrebno je odrediti i lokaciju gdje će se sadržaj prikazivati. Za provođenje istraživanja, koje web-stranice potrošači pretražuju kada imaju nekakav problem u Alexi su razvili alat pod nazivom: *Alexa Audience Overlap tool*. Potrebno je unijeti vlastitu web-stranicu, ili stranicu konkurenta u alat, zatim će se dobiti mapa koja prikazuje posjetitelje vlastite stranice, ili stranice konkurenta te stranice koje imaju slične posjetitelje kao unesena stranica, a prema tome se može odrediti i lokacija sadržaja, gdje će se plasirati.

#### 3. Alexa Audinece Overlap tool



Izvor: <https://blog.alexa.com/find-reach-audience-audience-overlap/>

Nakon što su pronađene stranice koje imaju posjetitelje slične vlastitim potrošačima, može se odrediti popis od nekoliko najslbližijih. Ovaj alat može biti koristan na dva načina, jedan je otkrivanje konkurenata i njihovih strategija i pristupa tržištu, a drugi je pronalazak potencijalnih

partnera. Pronalazak stranica koje dijele sadržaj koji se veže uz slične, ili iste teme, a da ne konkuriraju vlastitoj, može biti izvor za partnerstva i razvoj suradnje. Stoga je ovaj alat jako pogodan za praćenje stanja u industriji, pronalazak novih konkurenata, ali i potencijalnih partnera.

Kada su definirani konkurenti, može se upotrijebiti još jedan alat od Alexa-e: *Alexa Competitor Keyword Matrix*. Uz pomoć tog alata se mogu otkriti učestale riječi i teme koje konkurenti koriste te s njima privlače posjetitelje na svoje stranice. Takve informacije su jako korisne prilikom generiranja vlastitog sadržaja, ali i otkrivanja nedostataka ('gap') kod konkurenata. Stoga igra važnu ulogu u kreiranju vlastitog sadržaja, ali i otkrivanju prilika za generiranje novih posjetitelja, potencijalnih kupaca. Osim provjere konkurenata, može se upotrijebiti i za vlastitu provjeru stranica te u slučaju ako postoji nedostatak ('gap') to može značiti da se radi o nečemu što je bitno za industriju, a nedostaje i potrebno je nadopuniti.

#### 4. Alexa Competitor Keyword Matrix

Total keywords : 143,843

Use Cases + Filters + Toggle Columns Organic Paid Both Hide zero scores

Keywords	Popularity	Competition	Sites	bhg.com
☆ gallery wall	39	61	17	-
☆ small living room ideas	35	69	10	62
☆ diy	56	63	4	54
☆ bathroom ideas	44	70	35	72
☆ bedroom ideas	42	69	21	73
☆ living room ideas	42	67	15	70
☆ small bathroom ideas	40	69	17	70
☆ kitchen ideas	39	71	28	56
☆ bathroom designs	37	64	44	55
☆ farmhouse kitchen	37	55	3	56
☆ living room design	36	63	25	20

Izvor: <https://try.alexa.com/agency-plan>

Uz pomoć ovog alata se otkrivaju ključne riječi, preko kojih posjetitelji dolaze do određenih stranica. Na temelju izvješća ovog alata, može se za svakog konkurenta odrediti koje teme, ili riječi upotrebljavaju za generiranje prometa na stranici, te da li se radi o plaćenim oglasima, ili organskom prometu, tj. posjetiteljima koji su došli do stranice putem tražilice. Ovisno o tome

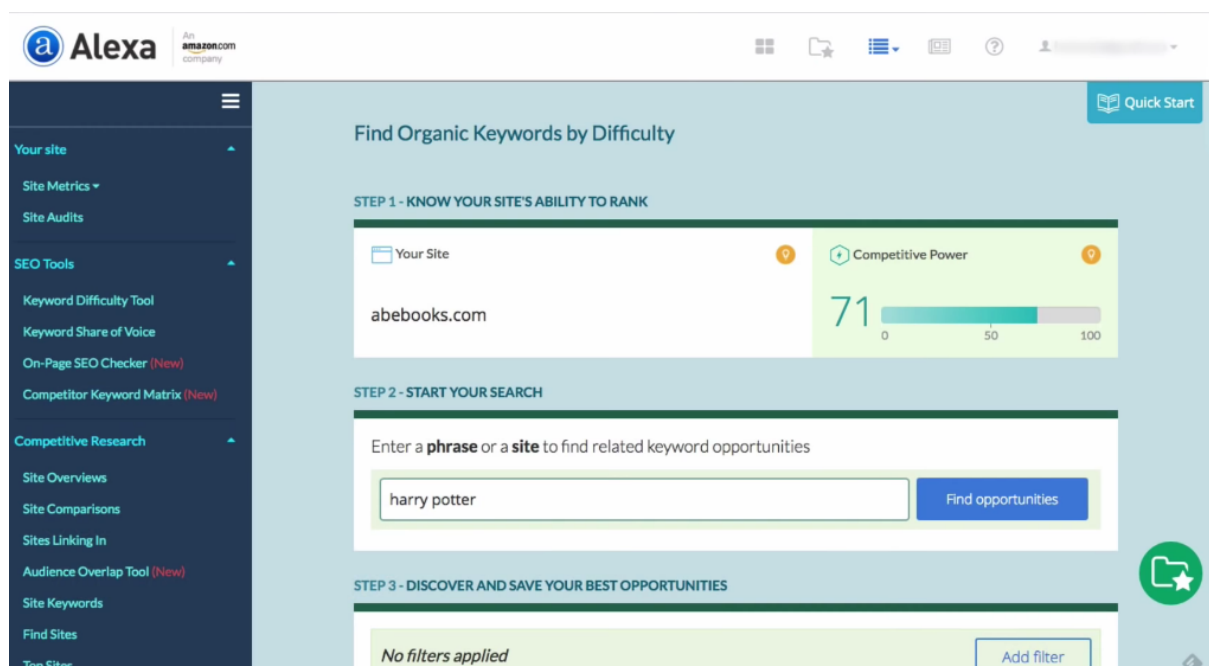
može se odrediti, da li upotrijebiti plaćene oglase, ili pokušati ostvariti organski promet stranicom.

#### 4.3.2.1.2. Uloga Alexa Internet-a u fazi traženja informacija

Sljedeća faza u procesu donošenja odluke o kupovini je potraga za informacijama koje će riješiti potrošačev problem. Potrošač zna da problem postoji, ali još ne zna koje je rješenje. U ovoj fazi potrošač traži informacije uz pomoć kojih će bolje razumjeti svoj problem kako bi identificirao rješenje svog problema. Stoga je potrebno osigurati vidljivost marke te osigurati da potrošač dospje u prodajni lijevak.

Kada su potrošači u potrazi za potencijalnim rješenjem postoje brojni mogućnosti, a svatko se bori da potrošač završi u njegovom prodajnom lijevku. Stoga je u ovoj fazi bitno kreirati sadržaj za gornji dio lijevka, odnosno set informacija koji će privući pažnju što većeg broja potrošača. Za potrebe razvijanja takvog sadržaja razvijen je alat: *Alexa Keyword Difficulty Tool*. Alat se upotrebljava tako da se unese pojam određene industrije u kojoj se djeluje te on generira popis tema prema relevantnosti, popularnosti i odnosu prema drugim temama. Prema tome se kreira sadržaj na teme koje su relevantne i popularne, što ukazuje na to da su ti pojmovi pretraživani.

#### 5. Alexa Keyword Difficulty Tool




Izvor: <https://try.alexa.com/marketing-stack/keyword-difficulty-tool>

Uz pomoć ovoga alata mogu se odrediti ključni pojmovi/teme koje se vežu uz industriju, a osim toga kakve su mogućnosti u odnosu na konkurenciju. Dakle za određeni pojam se može provjeriti koliko je on upotrijebljen od konkurencije te se onda, sukladno mogućnostima, određuje da li konkurirati njima. Što netko ima veći broj posjetitelja, to je njegova konkurentska moć veća. Stoga je bitan odabir ključnih pojmova/tema, kako bi se izbjegla jača konkurencija. Nakon što se uz pomoć alata provede analiza ključnih pojmova/tema, može se provoditi analiza konkurenata, koliki promet ostvaruju, koliko su jaki, kako su rangirani te da li je moguće konkurirati njima. Osim toga, s alatom se na taj način može generirati popis pojmova/tema, koje se mogu upotrijebiti u budućnosti te se mogu pratiti njihovi pokazatelji kroz vrijeme. Na taj način se mogu spremati ideje koje se naknadno mogu realizirati.

#### *4.3.2.1.3. Uloga Alexa Internet-a u fazi vrednovanja alternativa*

Nakon što završi faza traženja informacija, potrošači započinju s vrednovanjem alternativa. U ovoj fazi potrošači vrednuju koja od identificiranih rješenja najbolje odgovara njihovim potrebama te prema tome vrednuju pojedinu opciju. Dakle, kada se potrošači nalaze u ovoj fazi oni imaju zamisao o rješenju koje im je potrebno, ali ne znaju još koje rješenje odabrati, odnosno istražuju koju marku odabrati. Kako bi potrošača pridobili u ovoj fazi u Alexa-i su razvili alat uz pomoć kojega se jednostavnije može razviti sadržaj koji je potreban za pridobivanje potrošača u središnji dio prodajnog lijevka. Za te potrebe su razvijeni alati za optimizaciju i vidljivost pretraživanja, koji se zovu *Alexa SEO Audit Tool* i *Alexa On-Page SEO Checker*. Prvi alat služi za analizu vlastite stranice, uz pomoć njega se dobiva izvještaj o tome kako je stranica optimizirana za tražilice, a uz to daje i preporuke što poduzeti, kako bi se poboljšali pokazatelji. Drugi alat se upotrebljava za analizu optimiziranost za tražilice za pojedine stranice. Unosi se URL i ključni pojam te stranice, a alat će analizirati kako je stranica strukturirana te dati savjete kako ju bolje strukturirati, kako bi se stranice češće pojavljivala u pretragama na internetu.

## 6. Alexa SEO Audit Tool

[← Home](#)  an Amazon.com company  [Take Tour](#) [Blog](#) [Support](#)

**Overall Grade** ?  
**B** 88/100  
Previous Report  
**B** 88/100

**Category Grades**

SEO	Performance	Security	HTML Tags	Reputation
<b>B</b> 81/100	<b>A</b> 99/100	<b>B</b> 88/100	<b>C</b> 75/100	<b>A</b> 98/100
Previous Report				
<b>B</b> 81/100	<b>A</b> 99/100	<b>B</b> 88/100	<b>C</b> 75/100	<b>A</b> 98/100

**Based On**

On-Site Pages	Off-Site Links
<b>7,506</b>	<b>4,998</b>
Previous Report	
<b>7,526</b>	<b>4,999</b>

**Recommended Action**

Here are the most important steps you can take to help improve your site's grade. Go to the topic for more details.

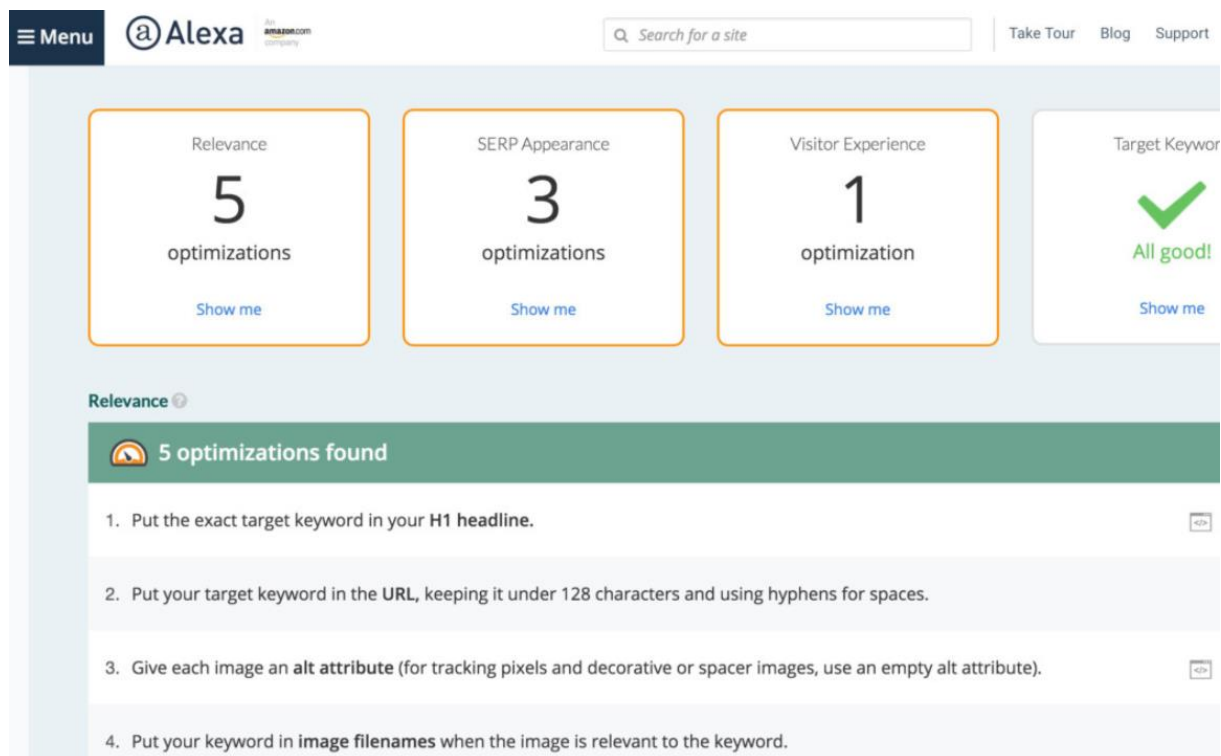
**SEO**

- 1. Give important pages unique titles. See [Duplicate Title Tags](#).
- 2. Shorten page titles to 65 characters or fewer. See [Long Title Tags](#).
- 3. Add links to hard-to-find pages. See [Reachability](#).
- 4. Replace redirects with direct links or reconfigure server. See [Redirects](#).
- 5. Replace generic anchor text. See [Anchor Text](#).
- 6. Fix broken links. See [Broken Links](#).
- 7. Shorten URLs to 128 characters or fewer. See [Long Urls](#).

Izvor: <https://try.alexa.com/advanced-plan>

Uz pomoć ovog alata se mogu dobivati redovni izvještaji (svaka dva tjedna za premium korisnike), a izvještaj donosi informacije o: optimiziranosti stranice, problemima s robots.txt-ima (kontrola pristupa stranici od strane programa koji automatski pregledavaju stranice na internetu, npr.: Google, Bing, itd.), brzini protoka podataka i sigurnosnim poteškoćama. Osim izvještaja, u slučaju da alat otkrije nekakve nedostatke nudi konkretne prijedloge za rješenje tih nedostataka. Prijedlozi za rješenje stižu s detaljnim uputama kako ih provesti, što znatno olakšava cjelokupni proces za korisnika. Nedostatke je moguće rješavati pojedinačno, ili sve odjednom, kako god, može se preuzeti dokument s izvještajem i uputama za rješavanje te se odvojeno od alata. Na taj način korisnik alata može upute proslijediti nekome drugom, bez da omogućava pristup alatu.

## 7. Alexa On-Page SEO Checker



Izvor: <https://try.alexa.com/advanced-plan>

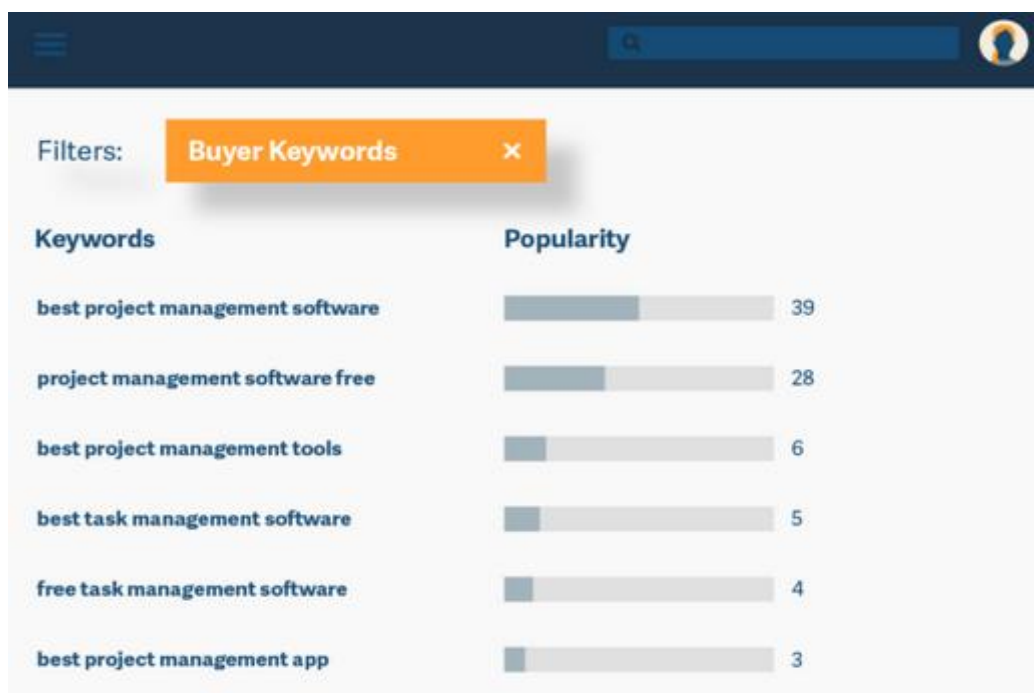
Uz pomoć ovoga alata se mogu dobiti korisne informacije o tome kako je stranica rangirana te kako ju optimizirati, kako bi pretraživanja na tražilici upućivala više korisnika na nju. Alat analizira i daje izvješće i upute kako optimizirati stranicu. Izvještaj je također moguće preuzeti u odvojeni dokument koji je moguće proslijediti programerima, ili dizajnerima, kako bi optimizirali stranicu, u slučaju da se samostalno provodi optimizacija, date su jasne upute kako ih provesti. Što smanjuje ovisnost o profesionalnim programerima, ili dizajnerima. Također alat provodi i analizu meta opisa (opis koji se dobije kada se pretražuje Internet, na kojega se može kliknuti te se potom završi na stranici s koje je opis) te ima omogućava da se vidi kako se nešto prikazuje prilikom pretraživanja.

### 4.3.2.1.4. Uloga Alexa Internet-a u fazi kupovine

U ovoj fazi je potrošač spreman donijeti odluku te kupiti predmet. Potrošač je donio odluku koji će to predmet, usluga, marka odnosno rješenje biti. Prikupljanje informacije i vrednovanje opcija je obavljeno, sada je potrebno omogućiti potrošaču da jednostavno provede proces kupovine. Za to je potrebno pojednostaviti proces kupovine te ga jasno istaknuti, kako bi kupcu bio lako uočljiv i jednostavno provediv, a za to se čestu koriste riječi koje jasno upućuju na izvršavanje kupovine.

Za određivanje ključnih riječi, koji će potaknuti potrošača da izvrši kupovinu u Alexa-i su razvili alat pod nazivom: *Alexa Competitor Keyword Matrix* (slika broj 4, poglavlja 4.3.2.1.). Ovaj alat omogućava pregled ključnih riječi koje konkurenti koriste. Potrebno je unijeti do deset konkurentskih stranica, zatim alat provodi analizu te daje izvještaj koje pojmove te stranice koriste kako bi potaknuli potrošača da kupi nešto. Na temelju tog izvještaja se može odrediti kako strukturirati vlastiti sadržaj na način da izazove djelovanje, odnosno potakne potrošača da kupi nešto.

#### 8. Koncept alata Alexa Competitor Keyword Matrix - 'okidači za kupovinu'



Izvor: <https://try.alexa.com/keyword-research>

Kao i kod faze spoznaje, tako se i u fazi kupovine može upotrijebiti *Alexa Competitor Keyword Matrix*, uz pomoć tog alata se mogu istražiti konkurenti te na koji način su oni potaknuli svoje posjetitelje da izvrše kupovinu. Prilikom korištenja alata je potrebno odabrati filter, koji će prepoznati pojmove koje potrošače potiču da izvrše kupovinu, okidače za kupovinu. Također se može provesti pretraživanje koje prepoznaje cijele fraze koje su učestale za određenu vrstu potrošača kada se odluče za kupovinu. Alat će prepoznati takve pojmove i fraze te ih rangirati prema popularnosti.

#### 4.3.2.1.5. Uloga Alexa Internet-a u fazi poslijekupovnog ponašanja

Posljednja faza procesa donošenja odluke o kupovini je poslijekupovno ponašanje. Potrošač je obavio kupovinu, ali time ne završava odnos između njega i prodavača/proizvođača. U ovoj

fazi potrošač otkriva, da li je donio točnu odluku te koliko je ona u skladu s njegovim očekivanjima, a sukladno tome potrošač će biti zadovoljan ili nezadovoljan kupovinom i/ili predmetom kojeg je kupio. Ova faza je malo drugačija od prethodnih, prvenstveno radi toga, što se do ove faze ne može doći, a da joj ne prethodi faza kupovine. Iako se čini da je ovo zadnja, završna faza, tome nije tako. Ovu fazu je početak razvijanja dugoročnog odnosa s potrošačem. U ovoj fazi je poznato za što je zainteresiran potrošač, stoga je potrebno poduzimati radnje koje će potaknuti ponovnu kupovinu. Za ovu fazu se također upotrebljava od Alexa-e alat: *Alexa Competitor Keyword Matrix* (slika broj 4, poglavlja 4.3.2.1.), uz pomoć kojega se analizira na koji način konkurenti održavaju odnos sa svojim kupcima.

#### 9. Koncept alata Alexa Competitor Keyword Matrix - ključni pojmovi/teme



Izvor: <https://try.alexametrics.com/keyword-research>

Alat omogućava da se otkrije koji su najznačajniji konkurenti po određenoj temi ili pojmu te se prema tome može definirati vlastita strategija, ovisno o tome da li postoje sredstva kako bi se konkuriralo njima. Osim toga, uz pomoć tog alata se mogu identificirati i ključne teme i pojmovi koji generiraju promet za vlastitu stranicu, što ukazuje na postojanje potencijala za razvijanje dugoročnog odnosa. Prema tome se može zaključiti za koje teme, ili područja određene industrije je netko referentna točka, gdje potrošači potražuju odgovore za svoja pitanja. Također se mogu detektirati i nedostaci ('gap') i na temelju toga generirati sadržaj koji će privući potrošača i stvoriti dugoročan odnos s njima.

#### 4.3.2.1.6. Zaključak o Alexa Internet-u

Može se zaključiti kako je uloga Alexa Internet-a, tj. alata koje nude, značajna za njihove korisnike u provođenju marketinške strategije. Drugim riječima, uloga umjetne inteligencije se



ovdje ističe na strani proizvođača, odnosno prodavača. Prodavači pomoću ovih alata jednostavnije segmentiraju i targetiraju ciljano tržište, što im olakšava posao, ali i smanjuje troškove. Osim toga omogućuje im direktniji pristup ciljanom tržištu što u konačnici utječe na prihode, tj. omogućuje veće prihode. Alexa Internet alati kontinuirano prateći, prikupljajući i analizirajući kretanje i ponašanje potrošača na internetu, minorizira ulogu pružatelja usluga istraživanja tržišta, jer se radi o kontinuiranom prikupljanju podataka većeg uzorka, što njihove implikacije čini relevantnijima, ali treba istaknuti kako su ograničeni samo na internet korisnike.

Pored uloge za korisnike, prodavače, alati su značajan izvor podataka za Amazon, odnosno za razvijanje njihovog umjetno inteligentnog sustava Alexa. Kako je navedeno u radu, jedan od većih izazova koji očekuje umjetnu inteligenciju je količina podataka. Kako bi umjetna inteligencija zaživjela, ključno će biti osigurati dovoljno količinu podataka iz koje će moći generirati svoje znanje. Stoga se može pretpostaviti kako su u Amazonu upravo prikupljajući podatke o ponašanju potrošača htjeli stvoriti bazu iz koje će njihov umjetno inteligentni sustav učiti i postati kućni asistent za konačne potrošače.

#### **4.3.2.2. Amazon Alexa kućni asistent**

Amazon Alexa, ili samo Alexa je virtualni asistent koji je razvije od strane Amazona, a koristi se preko *Amazon Echo-a*, zvučnika kojeg je također razvio Amazon, odnosno njihova podružnica Amazon Lab126. Alexa kućni asistent izdan je prvi puta 2014. godine, a sposoban je za govornu interakciju, reprodukciju glazbe, izradu popisa obveza, postavljanje alarma, reprodukciju podcasta, reprodukciju audio knjiga i pružanje vremenskih, prometnih, sportskih i drugih informacija u stvarnom vremenu. Također pomoću njega se može upravljati s drugim pametnim uređajima u kućanstvu. Korisnici mogu proširiti Alexa mogućnosti instaliranjem 'vještina' (*skill*), koje su najčešće razvijene od strane trećih strana, izvan Amazona. Najvišu razinu funkcionalnosti Alexa kućni asistent ima u SAD-u. (Wikipedia, 2019.)

Iako se radi o istom nazivu kao kod podružnice koja je razvija alate za praćenje i analizu prometa na internetu, riječ je o dva odvojena poduzeća. Amazon po tom pitanju nema komentara, tj. ne žele navesti kakva je povezanost između ta dva poduzeća, što navodi i Christian (2017.) u članku. On ipak sumnja da postoji povezanost između ta dva poduzeća te navodi kako je neobično, pogotovo obzirom na veliki vremenski razmak osnivanja, da se dva poduzeća nazovu istim imenom.

Stoga se može pretpostaviti kako će Alexa Internet, prikupljenim podacima služiti Alexa kućnom asistentu kao baza podataka iz koje će učiti. Ovaj potez Amazona bi bio logičan, obzirom da se s jedne strane radi o umjetnoj inteligenciji koja će služiti kao kućni asistent, a s druge o podacima o ponašanju krajnjih korisnika. Na taj način mogu prikupljati relevantne podatke koji su im potrebni za usavršavanje umjetne inteligencije, ali i dodatno razvijati alate koji će prikupljati takve podatke. U konačnici ako bi se ta dva sustava integrirali u jedan, mogao bi rezultirati umjetno inteligentnim asistentom, koji preuzima ulogu potrošača. U tom slučaju, potrošača bi zamijenila Alexa te bi ona, prema tome što je naučila o svom korisniku, donosila odluke umjesto njega.

#### **4.3.2.3. Amazon Basics**

Amazon Basics je privatna marka Amazona, koja nudi kućne i uredske potrepštine i tehničku opremu. Od 2017. godine Amazon Basics je najprodavanija marka na Amazon.com-u. Godine 2018. Amazon je proširio svoj asortiman na predmete za renovaciju kuće nudeći opremu za kuhinju i kupaonicu. U 2018. godini se objavila popis igračaka Amazon Basics-a, iako nisu potvrdili da postoje planovi o širenju privatne marke na igračke (Wikipedia, 2019.).

Obujam i pristup podacima o kupovini koji su dostupni Amazonu, daje im jedinstvenu prednost kod predviđanja potražnje. Stoga, analizirajući što kupci pretražuju, odabiru i kupuju im omogućava da brzo i jeftino dodaju nove proizvode u asortiman privatne marke. Tako da kada primijete da određeni proizvod, koji nije dio privatne marke, previše uspješan, Amazon može stvoriti vlastitu verziju i na kraju spriječiti takav uspjeh. Također, kada otkriju da neki proizvod ne ostvaruje zadane profite, mogu brzo i jednostavno ukinuti ga iz ponude.

Kada se promatra uloga privatne marke za potrošača, tu se prvenstveno ističe cijena, odnosno proizvodi Amazon Basics-a su cjenovno konkurentniji, tj. povoljniji, što predstavlja dodatni izazov za druge prodavače na Amazonu. Pored toga dodatni izazov, kada potrošač putem umjetno inteligentnog sustava Alexa-e naručuje te prilikom toga ne istakne određenu marku proizvoda, umjetno inteligentni asistent će uvijek naručiti predmet privatne marke, odnosno Amazon Basics-a, kada on postoji u asortimanu.

Konačno za kupca je Amazon Basics iznimno koristan, s jedne strane ima manju cijenu od drugih marki, a s druge pojednostavljuje donošenje odluke za potrošača i to prvenstveno kod predmeta kod kojih je razina uključenosti u donošenje odluke kod niska. Također kada se radi

o prodavačima, Amazon Basics predstavlja dodatni izazov za njih, osim što se natječu s drugim prodavačima, natječu se i sa samim Amazonom. Stoga je za njih ključno osigurati sve relevantne informacije o proizvodu potrošačima, a pored toga, kako bi bolje konkurirali drugima i Amazonu, da u ponudi imaju proizvode koje zadovoljavaju potrebe određene niše.

#### **4.3.3. Intervju s korisnicima Amazon.com-a**

Za potrebe rada provedena su dva dubinska intervju s osobama koje su koristili Amazon Alexa-u na području SAD-a. Ispitane osobe su boravili određeno vrijeme (više od šest mjeseci) na području SAD-a te svakodnevno koristili Amazon Alexa-u stoga su imale priliku upoznati se bolje s mogućnostima koje nudi Amazonov umjesto inteligentni sustav- Alexa. Ispitanici su primarno upotrebljavali umjetno inteligentni sustav za potrebe reprodukcije glazbe, zatim kao izvor informacija, a osim toga su iskušavali i na koji način se odvija kupovina uz pomoć umjetno inteligentnog asistenta. Stoga će se u nastavku prikazati uloga Alexa-e umjetno inteligentnog asistenta kroz faze procesa donošenja odluke.

Trenutno Alexa glasovni asistent u fazi spoznaje problema nema značajniju ulogu, asistent ne prepoznaje kada njegov korisnik ima potrebu za nečim. Iako je kako ispitanici navode za očekivat: „... da će Alexa kada se dodatno razvije moći održavati povezane uređaje, što znači da će moći prepoznati na primjer kada svjetlo ne radi i naručiti novu žarulju samostalno.“ Što drugim riječima znači da Alexa kućni asistent još nije razvijen do te mjere da prepoznaje potrebu svoga korisnika.

Kada je riječ o prikupljanju informacija, trenutno virtualni asistent ima veliku bazu podataka, odnosno informacija. Obzirom da Amazon ima velik asortiman proizvoda, raspolaže s velikom bazom podataka, odnosno informacija, što u konačnici omogućava jednostavno prikupljanje informacija umjetno inteligentnom sustavu. Dakle može se pretpostaviti kako Alexa ima pristup informacijama vezanim za predmete te ih lako može pretraživati.

Zatim kada je riječ o fazi evaluacije alternativa, odgovori ispitanika upućuju na to, da ova faza ovisi o uključenosti njih u proces donošenja odluke o kupovini. Prema riječima ispitanika: „kada se radi o predmetu koji je za mene vrijedan, odnosno ima dodatnu vrijednost, a ne samo funkcionalnu, tada istražujem karakteristike proizvoda, a bitna mi je i marka predmeta. Primjer je oprema za plivanje, koja je morala biti marke Speedo. Dok kada sam kupovao baterije, nije mi bila bitna marka, nego samo da su baterije koje su meni potrebne“ Drugim riječima, kada su

ispitanici htjeli kupiti određeni predmet te znali točno što žele pretraživali bi ga prema marki, odnosno dali bi naredbu Alexa-i da žele proizvod određene marke. Zatim kada bi se radilo o predmetima koji nisu standardizirani, odnosno zahtijevaju određenu razinu uključenosti potrošača, a korisnik samo navede da želi određenu kategoriju kojoj pripada određeni predmet, Alexa bi dala nekoliko preporuka na temelju kojih korisnik zatim donosi odluku. Dok kada je kod proizvoda koji su bili standardizirani Alexa najčešće nakon naredbe odabrala proizvode iz *Amazon Basics* asortimana te čekala naredbu da se potvrdi kupovina. Iako u toj situaciji je bilo moguće odabrati određenu marku, jedino je bilo potrebno navesti ju u naredbi.

Promatra li se faza kupovine u procesu donošenja odluke o kupovini, ova faza je pod znatnim utjecajem korisnika. Odnosno, dok korisnik ne kaže Alexa-i da provede kupovinu, umjetno inteligentni sustav ju ne provodi. Kako ističu ispitanici: „Dopustio bih da Alexa provodi ovu fazu u procesu, ali pod uvjetom da mogu zadati uvjete u kojima Alexa može provesti samostalno kupovinu, ali Alexa još nije dostigla tu razinu umjetne inteligencije koja je potrebna. Stoga i kada ju dostigne prvo bih se htio uvjeriti da zaista donosi dobre odluke.“ Bitno je istaknuti kako u ovoj fazi umjetno inteligentni sustavi, kao što je Alexa, ovise o općem razvoju umjetne inteligencije. Stoga dok umjetna inteligencija ne dostigne određenu razinu znanja, sustavi poput Alexa-e neće moći donositi samostalno odluku te će odluka za ili protiv nečega ovisi o konačnom sudu čovjeka.

Gleda li se posljednja faza procesa donošenja odluke o kupovini, a to je poslijekupovni procesi, Alexa u njoj nema ulogu. Pretpostavlja se kako će ju imati kada bude u mogućnosti povezati se s više uređaja u kući te umjetno inteligentni sustav Alexa bude taj koji će upravljati tim uređajima i prepoznaje potrebe korisnika i kućanstva. Iako Amazon internet trgovina, već danas, kako potvrđuju i ispitanici: „Amazon iznimno dobro prati ponašanje potrošača na internetu te provodi unakrsnu prodaju, daje preporuke za komplementarna dobra i oglašava određene proizvode kada pretpostave da je korisnik potrošio zalihe, što se znalo dešavati za papirnate ručnike i slično.“ Ova izjava potvrđuje da Amazon prati ponašanje svakog pojedinog potrošača kao individuu te prilagođava ponudu i oglase njoj.

Iako se čini da uloga umjetno inteligentnih asistenata u procesu donošenja odluke o kupovini ograničena, bitno je naglasiti kako je razvoj umjetne inteligencije na početcima i iznimno zahtjevan pothvat te će biti potrebno uložiti znatne resurse u njega. Obzirom da će za razvoj umjetne inteligencije, kako je navedeno i u radu, važnu ulogu imati podatci, Amazon je razvio brojne alate koji prikupljaju podatke, odnosno informacije o ponašanju potrošača na internetu.

Za pretpostaviti je kako će prikupljanje podataka putem alata koje su razvili uz interakciju s korisnicima, odnosno potrošačima znatno doprinijeti i ubrzati razvoj umjetne inteligencije

#### 4.4. Rasprava

Pretpostavka je kako Amazon uz pomoć svog glasovnog asistenta želi znatno pojednostaviti proces donošenja odluke o kupovini, to jest u nekim situacijama čak i u potpunosti preuzeti ulogu potrošača. Dakle riječ je o tome da proces donošenja odluke o kupovini prelazi s potrošača na Alexa-u. Stoga je ključno za Amazon razumijevanje procesa donošenja odluke, te procesa primanja informacije, obrade informacije te u konačnici i donošenja odluke. Promatra li se to u kontekstu AIDA modela, pretpostavka je kako će Alexa, glasovni asistentu, u konačnici, kada tehnologija dostigne odgovarajuću razinu te umjetna inteligencija dostigne sposobnosti koje su potrebne, ona moći zamijeniti čovjeka u tom pogledu. Bitno je napomenuti, kako je i Wijaya (2015.) istaknuo, na nedostatak AIDA modela, odnosno ne uzimanje u obzir poslijekupovne procese, stoga se za potrebe ovoga rada AIDA model u istraživanju promatralo kao prošireni model, gdje se uzima u obzir i lojalnost potrošača, a model se naziva AIDAL, a 'L' označava *loyalty* (eng. lojalnost).

Zbog svega navedenog Amazon trenutno velike napore ulaže u prikupljanje podataka o ponašanju potrošača, jer kako je prethodno u radu navedeno, ključni izazov za razvoj umjetne inteligencije neće biti algoritam, nego količina podataka koja je potrebna takvom sustavu kako bi bio funkcionalan. Alati koje su razvili, a prvenstveno služe prikupljanju podataka i analizi istih, pokrivaju proces donošenja odluke o kupovini te ga promatra na način, da prikuplja podatke o tome što izaziva *Attention* (pažnju), *Interest* (interes), *Desire* (želju), *Action* (pothvat) i *Loyalty* (lojalnost). Osim alata, koji prikupljaju podatke o ponašanju potrošača, broj vještina (*skill*) koje ima Alexa glasovni asistent je u znatnom porastu. U 2018. godini se broj vještina prema Kinsella-u (2019.) više nego udvostručio u SAD-u, u Ujedinjenom Kraljevstvu je broj narastao za 233%, a u Njemačkoj 152% te brzina porasta broja vještina je također u porastu. Vještine predstavljaju programe kao što su prognoze vremena, upravljanje rasvjetom, televizijom, usisavačem i svime što ima mogućnost daljinskog upravljanja i kompatibilno je s Alexa-om. Na taj način pružatelji usluga, ali i prodavači proizvoda žele dodatno učvrstiti svoju vezu s potrošačem.

Uz navedeno je bitno istaknuti kako pored prikupljanja podataka i razvoja umjetno inteligentnog sustava, Amazon u vlastitom asortimanu nudi i vlastite proizvode pod nazivom

*Amazon Basics*, koji obuhvaćaju brojne predmete za kućne potrebe, koji zadovoljavaju standardne norme kvalitete, što su potvrdili i ispitani korisnici: „kada je riječ o njihovim proizvodima, to su jeftiniji proizvodi, a razlika u kvaliteti se gotovo ne primjeti.“ Može se pretpostaviti kako s tim Amazon želi upotpuniti cijelu priču, odnosno stvoriti 'eko sustav', gdje uređaji međusobno komuniciraju, a Alexa postaje sustav koji upravlja i održava pojedini sustav, odnosno održava pojedine domove. Alexa će moći samostalno, ili uz minimalno sudjelovanje vlasnika, kupovati žarulje, baterije, deterdžent, namirnice i slično. Kada se umjetna inteligencija usavrši, Amazon će uz pomoć umjetno inteligentnog sustava Alexa-e održavati i opskrbljivati domove diljem svijeta samostalno.

Naposljetku uzmu li se u obzir mogućnosti, resursi, a i trenutni doseg, kojeg su postigli u Amazonu po pitanju umjetne inteligencije, Alexa-e, može se pretpostaviti kako Alexa ima potencijal postati platforma koja će objedinjavati sve ili većinu postojećih platformi. Preuzimanje procesa donošenja odluke o kupovini i široki asortiman koji zadovoljavaju potrebe kućanstva su tek početak Amazona, odnosno Alexa-e. Bitno je istaknuti i broj *skill-ova* (aplikacija) čiji rast ubrzava, a time Alexa zauzima središnju ulogu u budućnosti, odnosno ima potencijal zamijeniti postojeće sustave, koji se primjenjuju na pametnim uređajima te ih objediniti u jedan, na što upućuju i odgovori ispitanika.

#### **4.5. Ograničenja istraživanja**

Kada se promatraju rezultati ovoga istraživanja treba imati na umu ograničenja ovog istraživanja. Najznačajnije ograničenje predstavlja broj ispitanika na kojemu je proveden dubinski intervju. Također bitno je napomenuti kako su ispitanici bili samo privremeni korisnici predmeta istraživanja te da nisu testirali sve mogućnosti umjetno inteligentnog sustava. Pored toga treba navesti i subjektivnost ispitivača prilikom interpretiranja kvalitativnog istraživanja, obzirom na neiskustvo u provođenju takve vrste istraživanja.

Stoga važno za istaknuti kako su ispitanici bili privremeni korisnici predmeta istraživanja. Predmet istraživanja trenutno najvišu razinu funkcionalnosti, ostvaruje na području SAD-a, a obzirom da su ispitanici proveli određeno razdoblje u SAD-u, bili su pogodni za dubinsko intervjuiranje. Osim ograničenog iskustva, obzirom na način ispitivanja, potrebno je uzeti u obzir i subjektivnost ispitanika.

Također, dubinskim intervjuom se ispituju prijašnja iskustva, stoga rezultati ovise o mogućnosti ispitanika da se prisjete relevantne situacije. Osim ograničenja vezanih za intervju, bitno je naglasiti i ona vezana uz dostupnost, odnosno nedostupnost internih podataka Amazona i njegovih podružnica. Provođenje eksperimenta, ili praćenje korisnika u procesu donošenja odluke o kupovini u pojedinim fazama procesa dali bi relevantnije rezultate.

## 5. Zaključak

Proces donošenja odluke o kupovini je iznimno kompleksan proces te na njega utječu brojni čimbenici, kako vanjski iz okoline pojedinca, tako i unutarnji odnosno osobni. Stoga je proces donošenja odluke o kupovini specifičan za svakog pojedinca i predstavlja izazov za svakog marketinškog stručnjaka. S druge strane je umjetna inteligencija, čiji razvojni potencijal nije dostignut, a sposobna je obraditi velike količine podataka te iz njih učiti i na taj način generirati znanja o svakom potrošaču zasebno. Može se pretpostaviti, a i istraživanje provedeno u ovome radu upućuje na to, kako će umjetno inteligentni sustavi jednoga dana velikim dijelom preuzeti ulogu potrošača u procesu donošenja odluke o kupovini. Ljudi već danas mogu umjetno inteligentne sustave poput Alexa-e povezivati s raznim uređajima te na taj način putem jednog uređaja upravljati ostalima. Osim toga mogu već jednostavnim glasovnim naredbama izvršiti kupovinu, a kada umjetno inteligentni sustavi dostignu potrebnu razinu razvoja, oni će biti sposobni učiti na temelju ponašanja njihovih korisnika te moći i samostalno donositi određene odluke.

Istraživanje pokazuje kako Amazon ulaže znatno napore kako bi pristupio jednom od najznačajnijih problema razvoju umjetne inteligencije, a to je količina podataka. Kako je u radu navedeno, dugo je algoritam bio u fokusu razvoja umjetne inteligencije, iako će značajniji izazov biti da se osigura dovoljna količina podataka, iz kojih bi ti sustavi 'učili'. Stoga su u Amazonu razvili niz alata koji prikupljaju informacije o ponašanju potrošača na internetu, a obzirom na broj korisnika interneta, osigurali su si pristup velikoj količini podataka. Alati su razvijeni na takav način da prikupljaju podatke kako bi mogli identificirati potrošače, ili obrasce njihova ponašanja, u svakoj fazi procesa donošenja odluke o kupovini. Osim toga alati prikupljaju podatke na temelju kojih se može provoditi segmentacija tržišta koja uzima u obzir preferencije individualnih potrošača, a u konačnici i cijenu je moguće definirati za svaku osobu individualno, tj. moguće je cjenovno diskriminirati svakog kupca.

Također je značajno napomenuti i asortiman kojeg ima Amazon. Amazonov asortiman proizvoda je iznimno širok, a posebno istaknuta je njihova vlastita robna marka- *Amazon Basic*, a u tom asortimanu se nalaze predmeti iz raznih kategorija. Pored asortimana i napora uložениh u razumijevanje ponašanja potrošača, bitno je istaknuti i funkcionalnosti koje ima umjetno inteligentni osobni asistent Alexa, a to su *skill-ovi* (vještine). Broj *skill-ova* ubrzano raste, a doda li se tomu još asortiman i razumijevanje potrošača, može se pretpostaviti kako će Amazon omogućiti da se njihovim umjetno inteligentnim sustavom Alexa upravlja cijelim kućanstvima



(tzv. *smart home*), a to bi u konačnici moglo dovesti do toga da Alexa zamijeni postojeće platforme, tj. da se funkcionalnosti današnjih platformi ujedine u Alexa-i.

Stoga u konačnici se može reći kako će umjetna inteligencija donijeti i znatne promjene u pogledu upravljanja procesom donošenja odluke o kupovini. Umjetna inteligencija će zamijeniti čovjeka u procesu donošenja odluke o kupovini, ako ne u potpunosti, onda djelomično, a to će utjecati i na marketinšku komunikaciju, odnosno AIDA(L) model više neće vrijediti, obzirom da se on odnosio na kognitivne, afektivne i bihevioralne varijable, odnosno na potrošačevo znanje, osjećaje i motivaciju za djelovanje. Na posljetku kao poseban izazov treba istaknuti strategiju, koja u takvim okolnostima, gdje u središtu neće biti potrošač, nego umjetno inteligentni sustav koji znatno utječe, odnosno određuje konačnu odluku.

Može se zaključiti kako Amazonov umjetno inteligentni sustav ima mogućnosti zauzeti središnju ulogu u procesu donošenja odluka o kupovini. U konačnici bi to značilo za proizvođače da se ne obraćaju potrošačima izravno, nego putem njihovih umjetno inteligentnih asistenata. Amazon ima znatan udio u tom pogledu, ali još je teško predvidjeti konačni ishod obzirom da mogućnosti i funkcionalni dosezi umjetne inteligencije još nije moguće jasno definirati. Ali prema istraživanju je indikativno da je Amazon sa svojim umjetno inteligentnim sustavom Alexa zauzeo čvrstu poziciju te ima preduvjete postati ključni 'igrač' u tom području.

## Popis izvora

1. Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge & Data Engineering*, (6), 734-749.
2. Agrawal, A., Gans, J., & Goldfarb, A. (2017). How AI will change the way we make decisions. *Harvard Business Review*.
3. Ajzen, I. (2008). Consumer attitudes and behavior. *Handbook of consumer psychology*, 1, 525-548.
4. Bennett, P. D., Kassarian, H. H. (1972). *Consumer behavior*. Englewood Cliffs, N.J.: Prentice-Hall.
5. Blackwell, R. D., Miniard, P. W., & Engel, J. F. (2001). *Consumer Behavior*: Harcourt College Publishers. Engelbrecht, A. P. (2007). *Computational intelligence: an introduction*. John Wiley & Sons.
6. Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User modeling and user-adapted interaction*, 12(4), 331-370.
7. Burke, R., Felfernig, A., & Göker, M. H. (2011). Recommender systems: An overview. *Ai Magazine*, 32(3), 13-18.
8. Business Insider (2019.), 9 things you probably didn't know about Amazon, < <https://www.businessinsider.com/amazon-jeff-bezos-facts-brand-history-name-2019-3> > Pristupljeno 01.09.2019
9. Christian J., (2017.), Why does Amazon have two completely different products called Alexa?, *The Outline*, dostupno na: < <https://theoutline.com/post/2377/why-does-amazon-have-two-completely-different-products-called-alexa?zd=2&zi=zmlfzkip> > Pristupljeno 02.09.2019.
10. CNBC, (2019.), Amazon says this year's Prime Day surpassed Black Friday and Cyber Monday combined, < <https://www.cnbc.com/2019/07/17/amazon-announces-prime-day-2019-results.html> > Pristupljeno: 03.09.2019.
11. Dholakia, R. R. (1978). Personality trait theory and consumer behaviour. *Vikalpa*, 3(2), 111-120.
12. Dudovskiy, J. (2013) *Consumer Decision Making Process: A Detailed Analysis*, *Research-Methodology.net* (online), dostupno na: <http://research-methodology.net/consumer-decision-making-process-a-detailed-analysis/> > . Pristupljeno 04.09.2019.
13. Egan, J. (2007). *Marketing communications*. Cengage Learning EMEA.
14. Engel, F.J., Blackwell, D.R., Miniard, W.P., *Consumer Behavior*, The Dryden Press, 1995, p.4

15. Engelbrecht, A. P. (2007). Computational intelligence: an introduction. John Wiley & Sons.
16. Erasmus, A. C., Boshoff, E., & Rousseau, G. G. (2001). Consumer decision-making models within the discipline of consumer science: a critical approach. *Journal of Consumer Sciences*, 29(1).
17. Gabrani, G., Sabharwal, S., & Singh, V. K. (2016, November). Artificial Intelligence Based Recommender Systems: A Survey. In *International Conference on Advances in Computing and Data Sciences* (pp. 50-59). Springer, Singapore.
18. Grewal, D., Roggeveen, A. L., & Nordfält, J. (2017). The future of retailing. *Journal of Retailing*, 93(1), 1-6.
19. Gupta, N., 2017, A Literature Survey on Artificial Intelligence, *INTERNATIONAL JOURNAL OF ENGINEERING RESEARCH & TECHNOLOGY (IJERT) ICPCN – 2017* (Volume 5 – Issue 19)
20. House, W. (2016). Artificial intelligence, automation, and the economy. Executive office of the President. <https://obamawhitehouse.archives.gov/sites/whitehouse.gov/files/documents/Artificial-Intelligence-Automation-Economy>.
21. Kaplan, J., (2017) Artificial Intelligence: Think Again. *Communications of the ACM* 60: 36-38.
22. Kapoor, R., & Madichie, N. (2012). *Consumer Behaviour*. June, Tata McGraw-Hill, Noida, India.
23. Katsov, I., (2017). *Introduction to Algorithmic Marketing: Artificial Intelligence for Marketing Operations*. Ilia Katcov.
24. Kenton, W., (2018.), Hierarchy-of-Effects Theory, Investopedia, <  
<https://www.investopedia.com/terms/h/hierarchy-of-effects-theory.asp> >. Pristupljeno: 28.08.2019.
25. Kesić, T., 2006., Ponašanje potrošača, *Opinio*
26. Khan, M. A. (2007). *Consumer behaviour and advertising management*. New Age International.
27. Khusro, S., Ali, Z., & Ullah, I. (2016). Recommender systems: issues, challenges, and research opportunities. In *Information Science and Applications (ICISA) 2016* (pp. 1179-1189). Springer, Singapore.
28. Kinsella, B. (2019.) Amazon Alexa Skill Counts Rise Rapidly in the U.S., U.K., Germany, France, Japan, Canada, and Australia, <  
<https://voicebot.ai/2019/01/02/amazon-alexa-skill-counts-rise-rapidly-in-the-u-s-u-k-germany-france-japan-canada-and-australia/> >Pristupljeno: 04.09.2019.
29. Kotler, P., & Armstrong, G. (2010). *Principles of marketing*. Pearson education.
30. Kotler, P., Keller, L. K., (2008), *Upravljanje marketingom*, 12. izdanje, Mate str 191
31. Kristin, L., (2017) Artificial Intelligence, Automation, and the Economy. *Chinese American Forum*, 32: 22-23

32. Lewitt, H. J., Pomdy, L. R., (1973.) Readings in Managerial Psychology (second ed.), The University of Chicago Press
33. Loudon, D. L., & Della Bitta, A. J. (1984). Consumer behavior: Concepts and applications. McGraw-Hill Companies.
34. Makridakis, S. (2017). The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. *Futures*, 90, 46-60.
35. Michael, G. (2015) The Future of Artificial Intelligence: Benevolent or Malevolent? Skeptic (Altadena, CA)
36. Montaner, M., López, B., & De La Rosa, J. L. (2003). A taxonomy of recommender agents on the internet. *Artificial intelligence review*, 19(4), 285-330.
37. Munthiu, M. C. (2009). The Buying Decision Process and Types of Buying Decision Behavior. *Sibiu Alma Mater University Journals. Series A. Economic Sciences*, 2(4), 27-33.
38. Nadimpalli, M. (2017). Artificial Intelligence – Consumers and Industry Impact. *International Journal of Economics & Management Sciences*, 06(03)
39. Ofir, C., & Simonson, I. (2007). The effect of stating expectations on customer satisfaction and shopping experience. *Journal of Marketing Research*, 44(1),
40. Pan, Y. (2016). Heading toward artificial intelligence 2.0. *Engineering*, 2(4), 409-413.
41. Park, D. H., Kim, H. K., Choi, I. Y., & Kim, J. K. (2012). A literature review and classification of recommender systems research. *Expert systems with applications*, 39(11), 10059-10072.
42. Peter, J. P., Olson, J. C., (2010). Consumer behaviour and marketing strategy, McGraw-Hill.
43. Petty, R. E., Cacioppo, J. T., & Schumann, D. (1983). Central and peripheral routes to advertising effectiveness The moderating role of involvement. *Journal of consumer research*, 10(2), 135-146
44. Previšić, J., Ozrećić Došen, Đ., 2007., Osnove marketinga. Adverta. Str116
45. Renko, N. (2009). Strategije marketinga. Zagreb: Naklada Ljevak.
46. Rusell, S., & Norvig, P. (2016). Artificial Intelligence: A Modern Approach Global Edition.
47. Sarkar, A. (2018.), A study on consumer satisfaction with reference on amazon, <<https://www.slideshare.net/AmitSarkar82/consumer-satisfaction-on-amazon-online-shopping> > Pristupljeno 05.09.2019
48. Sharma, R., & Singh, R. (2016). Evolution of recommender systems from ancient times to modern era: a survey. *Indian Journal of Science and Technology*, 9(20), 1-12
49. Sharma. D., (2013.), CONSUMER KNOWLEDGE, *International Journal of Advanced Engineering Research and Technology (IJAERT)*

50. Singbo, O. G. (2009). Umjetna inteligencija u suvremenom biokibernetičkom svijetu. *Spectrum: ogledi i prinosi studenata teologije*, (3-4), 55-63.
51. Tanner, J. F., & Raymond, M. A. (2010). *Principles of Marketing v. 2.0*. Flat World Knowledge. Flat World Education, Inc., 2012.
52. Tauber, E. M. (1972). Marketing notes and communications: Why do people shop?. *Journal of marketing*, 36(4), 46-49.
53. Tkalac Verčić, A., Sinčić Ćorić, D., & Pološki Vokić, N. (2011). *Priručnik za metodologiju istraživačkog rada u društvenim istraživanjima*. Zagreb: MEP.
54. Turing, A. M. (2009). Computing machinery and intelligence. In *Parsing the Turing Test* (pp. 23-65). Springer, Dordrecht.
55. Valerjev, P., (2006.), Uloga umjetne inteligencije u istraživanju uma: povijest i perspektiva, Institut društvenih znanosti Ivo Pilar, < [https://www.pilar.hr/wp-content/images/stories/dokumenti/zbornici/mozak\\_i\\_um/mozak\\_i\\_um\\_105.pdf](https://www.pilar.hr/wp-content/images/stories/dokumenti/zbornici/mozak_i_um/mozak_i_um_105.pdf) > Pristupljeno: 28.08.2019.
56. Venkatesan, M., & Thangadurai, K. (2017). History and Overview of the Recommender Systems. In *Collaborative Filtering Using Data Mining and Analysis* (pp. 74-99). IGI Global.
57. Wijaya, B. S. (2015). The development of hierarchy of effects model in advertising. *International Research Journal of Business Studies*, 5(1).
58. Wikipedia (2019) Amazon (company) < [https://en.wikipedia.org/wiki/Amazon\\_\(company\)](https://en.wikipedia.org/wiki/Amazon_(company)) > Pristupljeno: 04.09.2019.
59. Wikipedia (2019.) Alexa Internet < [https://hr.wikipedia.org/wiki/Alexa\\_Internet](https://hr.wikipedia.org/wiki/Alexa_Internet) > Pristupljeno 01.09.2019.
60. Wikipedia (2019.) Alexa Internet, < [https://en.wikipedia.org/wiki/Alexa\\_Internet#Alexa\\_Traffic\\_Rank](https://en.wikipedia.org/wiki/Alexa_Internet#Alexa_Traffic_Rank) > Pristupljeno: 01.09.2019.
61. Wikipedia (2019.) Amazon Alexa < [https://en.wikipedia.org/wiki/Amazon\\_Alexa](https://en.wikipedia.org/wiki/Amazon_Alexa) > Pristupljeno 01.09.2019.
62. Wikipedia (2019.) List of Amazon brands <[https://en.wikipedia.org/wiki/List\\_of\\_Amazon\\_brands#AmazonBasics](https://en.wikipedia.org/wiki/List_of_Amazon_brands#AmazonBasics)> Pristupljeno: 02.09.2019.

## **Popis slika**

1. Složeni model ponašanja potrošača.....	4
2. Utjecaj na proces donošenja odluke potrošača.....	11
3. Alexa Audinece Overlap tool .....	34
4. Alexa Competitor Keyword Matrix .....	35
5. Alexa Keyword Difficulty Tool .....	36
6. Alexa SEO Audit Tool .....	38
7. Alexa On-Page SEO Checker.....	39
8. Koncept alata Alexa Competitor Keyword Matrix - 'okidači za kupovinu' .....	40
9. Koncept alata Alexa Competitor Keyword Matrix - ključni pojmovi/teme.....	41

## **Popis tablica**

1. Prikaz modela procesa prihvatanja novog proizvoda .....	15
2. Strategije utjecanja na ponašanje potrošača .....	16
3. Koraci za izradu strategije utjecanja na ponašanje potrošača .....	18
4. Povijesni pregled sustava preporuke .....	22
5. Povijesni pregled razvoja umjetne inteligencije.....	25
6. Tehnike umjetne inteligencije .....	27

## Prilozi

### Podsjetnik za dubinski intervju

- A. Za što se koristi Alexa
  - a. Koliko dugo koristite Alexu?
  - b. Koliko često koristite Amazon Alexa-u?
  - c. Za što ste ju sve koristili Alexu?
  - d. Što mislite za što sve Alexu koriste njeni najnapredniji korisnici?
  - e. Da li je Alexa povezana s drugim uređajima u vašem kućanstvu?
    - i. S kojim?
    - ii. Kako upotrebljavate druge uređaje koji su povezani s Alexom
- B. Način korištenja Alexe
  - a. Upotreba funkcija
    - i. Za što koristite Alexu da obavlja poslove umjesto vas? (budilica, svjetlo, pušta glazbu, kalendar,...)
    - ii. Kako upotrebljavajte za npr.: puštanje glazbe (ili koju već funkciju nabrojite)?
      - 1. Kako odabirete glazbu, da li kažu naziv, žanr, godinu, izvođača,...?
      - a. Jeste li zadovoljni glazbom koju vam pusti Alexa?
        - i. Ako niste, zašto? Što je krivo kod glazbe koja je bila puštena, da li ne odgovara željenom zahtjevu, ili iz subjektivnih razloga?
  - b. Kupovina
    - i. Što ste sve kupovali uz pomoć Alexe?
      - 1. Predmeti koji su trajni/potrošni
    - ii. Kako izgleda postupak kupovine?
      - 1. Kako odabirete proizvod (karakteristike/marka)?
        - a. Ako prema karakteristikama → Da li ste znali koja je marka proizvoda?
          - i. Ako da – da li je Alexa sama rekla o kojoj se radi
          - ii. Ako ne – da li ih je zanimalo koja marka → da/ne zašto?
        - b. Ako prema marki → da li ste znali za sve karakteristike?
          - i. Ako ne – da li ste ih pokušali saznati i kako?

2. Kako definirate količinu ako se radi o predmetu kod kojeg količina nije presudni faktor (npr.: pasta za zube: 100-150-200-250 ml)
3. Da li se što dešava nakon isporuke što bi istaknuli (oglas – komplementarna dobra ili isti proizvod nakon proteka određenog vremena, da li Amazon zna kada si potrošio papir)?
4. Da li je kada bilo potrebe za reklamacijom?
  - a. Ako da – koji su razlozi? (objektivni ili subjektivni / kvalitativni ili kvantitativni)
  - b. Kako izgleda postupak reklamacije

#### C. Očekivanja korisnika

##### a. Konkurencija

- i. Zašto koristite Alexu, a ne nekog drugog asistenta?
- ii. Što bi se moralo dogoditi da krenete koristiti nekog drugog asistenta, ili da prestanete koristiti Alexu?
- iii. Koje funkcije bi trebao imati neki drugi asistent, a da ga nema Alexa te da bi zbog toga promijenili asistenta?

##### b. Budućnost


- i. Što bi htjeli da Alexa može, a trenutno ne može, koje funkcije nedostaju, a vama bi bile od velike koristi (u SAD-u)?
- ii. Da li bi dopustili u budućnosti, kada to bude moguće, da vam Alexa u potpunosti preuzme 'održavanje' kućanstva?
  1. Ako da – kako to zamišljate?
  2. Ako ne – zašto?
- iii. Zamislite da možete kupiti putovanje (aranžman), automobil, ili kuću uz pomoć Alexe?
  1. Ako da – kako bi taj proces izgledao?
  - Ako ne – zašto ne?




# Životopis

## OSOBNE INFORMACIJE

Kesić Alen

 3. Kozari put 2. odvojak 102, 10000 Zagreb (Hrvatska)

 0997064909

 alen.kesic@gmail.com

Spol Muško | Datum rođenja 06/01/1994 | Državljanstvo hrvatsko

## RADNO ISKUSTVO

01/10/2018–

**Volonter**

Institut za inovacije, Hrvatska, Zagreb

01/10/2018–14/06/2019

**Demonstrator**

Ekonomski fakultet u Zagrebu, Katedra za marketing

01/01/2010–21/05/017

**Izbori RH (izborni odbor)**

Republika Hrvatska

## OBRAZOVANJE I OSPOSOBLJAVANJE

05/11/2018– danas

Diplomski svučilišni sdutij, Ekonomski fakultet u Zagrebu, Zagreb (Hrvatska)

01/10/2014–28/09/2018

Preddiplomski svučilišni sdutij, Ekonomski fakultet u Zagrebu, Zagreb (Hrvatska)

01/09/2008–31/06/2012

IV Gimnazija, Zagreb (Hrvatska)

01/09/2004–15/07/2008

Bundes Real Gymnasium Schloss Wagrain, Vöcklabruck (Austrija)

01/09/2000–15/07/2004

Regenbogenschule, Attnang-Puchheim (Austrija)

## OSOBNJE VJEŠTINE

Materinski jezik hrvatski

Ostali jezici	RAZUMIJEVANJE		GOVOR		PISANJE
	Slušanje	Čitanje	Govorna interakcija	Govorna produkcija	
njemački	C2	C2	C2	C2	C2
engleski	C1	C1	C1	C1	B2

Stupnjevi: A1 i A2: Početnik - B1 i B2: Samostalni korisnik - C1 i C2: Iskusni korisnik

Zajednički europski referentni okvir za jezike

Komunikacijske vještine Dobre komunikacijske vještine stečene na sezonskim poslovima u radu s ljudima različite dobi te radu u grupama. Vrlo jednostavno prilagođavanje novim ljudima i novoj vrsti posla. Volim raditi, svaki posao mi je novi izazov koji trebam savladati, iako možda nisam radio poslove slične svojoj struci znam da mi to ne bi bio nikakv problem.

Organizacijske / rukovoditeljske vještine Što se tiče same organizacije, nisam vodio nikakve timove i organizirao skupove, ali sam organiziran u svom privatnom životu tj. u onome što privatno radim: studij, dobrovoljni rad, rekreativne aktivnosti itd. Time hoću reći da mi organizacija nije nešto strano te da bih mogao raditi na poslovima gdje će se od mene zahtijevati organiziranost.

Digitalne vještine	SAMOPROCJENA				
	Obrada informacija	Komunikacija	Stvaranje sadržaja	Sigurnost	Rješavanje problema
	Iskusni korisnik	Iskusni korisnik	Samostalni korisnik	Samostalni korisnik	Samostalni korisnik

Digitalne vještine - Tablica za samoprocjenu

Vrlo dobro poznavanje paketa MS Office-a od osnovnog Word-a do malo zahtjevnijeg Excel-a, Outlook-a, Publisher-a ili PowerPoint-a. Često se služim internetom i različitim internetskim tražilicama, tako da mi pronalazak važnih informacija na internetu nije problem. Također sam vješt u samom tipkanju na kompjuteru. Poznajem osnovne programe grafičkog dizajna kao npr. PhotoShop.

Ostale vještine U slobodno vrijeme se često bavim sportom kao što je nogomet, teretana, bicikljanje, itd. Također često čitam tekstove vezane uz: sport, politiku, tehnologiju, automobile te općenito literaturu edukativnog karaktera.

Vozačka dozvola AM, B, BE